

**VŠB – Technická univerzita Ostrava**

**Fakulta elektrotechniky a informatiky**

**Katedra kybernetiky a biomedicínského inženýrství**

**Filtrace MR obrazu na základě metody  
Nonlocal Means**

MR Image Filtration based on the Nonlocal Means

VŠB - Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství

## Zadání diplomové práce

Student: **Bc. Mariusz Lipus**  
Studijní program: N2649 Elektrotechnika  
Studijní obor: 3901T009 Biomedicínské inženýrství  
Téma: Filtrace MR obrazu na základě metody Nonlocal Means  
MR Image Filtration based on the Nonlocal Means  
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování základních principů filtrace obrazu.
2. Nastudování evaluačních parametrů pro hodnocení kvality a efektivity filtrační procedury.
3. Rešerše filtračních metod a analýzy šumu pro MR obrazová data.
4. Nastudování principů filtrační metody Nonlocal Means.
5. Design a tvorba testovací datové báze MR obrazů.
6. Design a implementace filtrační procedury Nonlocal Means.
7. Testování a evaluace filtrace pro MR obrazová data.
8. Vyhodnocení efektivity a robustnosti filtrační metody pro variabilní MR obrazová data.
9. Analýza filtrační procedury pro modelování objektů z MR obrazových dat.
10. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN. *Handbook of biomedical image analysis*. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 0-306-48607-5.
- [2] JAN, Jiří. *Medical image processing, reconstruction, and restoration: concepts and methods*. Boca Raton, FL: Taylor & Francis, 2006. ISBN 0-8247-5849-8.
- [3] LANDINI, Luigi, Vincenzo POSITANO a Maria Filomena SANTARELLI. *Advanced image processing in magnetic resonance imaging*. Boca Raton, FL: CRC/Taylor & Francis, 2005. ISBN 0824725425.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2018

Datum odevzdání: 30.04.2019



doc. Ing. Jiří Koziorek, Ph.D.  
*vedoucí katedry*



prof. Ing. Pavel Brandštetter, CSc.  
*děkan fakulty*

## **Prohlášení**

*„Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně a uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.“*

V Ostravě 29. 4. 2019

*Matěj Dvořák*

## **Poděkování**

*Chtěl bych poděkovat Ing. Janu Kubičkovi, Ph.D. za vedení mé diplomové práce, cenné rady a odborný dohled.*

## Abstrakt

Tato diplomová práce je zaměřena na filtraci MR obrazových dat pomocí Non-Local Means filtru. Cílem této práce je design a realizace aplikace pro objektivní hodnocení a filtraci MR obrazů. Tato aplikace umožňuje nahrát nativní MR obrazová data, poškodit je vybranými šumy s konkrétními hodnotami šumových parametrů a následně je filtrovat pomocí Non-Local Means filtru. Součástí vyvinuté aplikace je i možnost obrazová data v různých fázích zpracování (nativní, zašuměné a filtrované) simultánně prohlížet a přepínat mezi sebou. Aplikace taktéž poskytuje informace o výsledcích hodnotících parametrů určující kvalitu filtrace. Práce je také zaměřená na testování Non-Local Means filtru na pěti vybraných datových sadách MR obrazů. Tyto datové sady byly účelově degradovány všemi deterministickými šumy použitými v této práci vektorem hodnot šumových parametrů. Tímto způsobem je možno sledovat a hodnotit dynamický efekt partikulárního šumu v kontextu konkrétních MR obrazů. V práci je uvedeno vyhodnocení a srovnání filtrace pouze pro dva vybrané šumy, včetně evaluačních grafů a tabulek pro jednu vybranou datovou sadu. Poslední část je zaměřena na vyhodnocení multilevel OTSU segmentace mezi nativním a zašuměným obrázkem, nativním a filtrovaným obrázkem ze dvou vybraných oblastí lidského těla pro dva vybrané šumy.

## Klíčová slova

MRI, typy šumů v obraze, typy filtrů, konvoluce, Non-Local Means filtr, hodnotící parametry filtrace obrazu, OTSU segmentace

## Abstract

This diploma thesis is focused on filtration of MR image data by means of Non-Local Means filter. The aim of this thesis was to design an application for objective evaluation and filtration of MR images. In such application MR images can be downloaded, damaged by particular noises with selected values of noise parameters, and subsequently filtered by using the Non-Local Means filter. Part of the developed application makes it possible to carry out simultaneous examination of image data in individual stages of processing as well as switching between undamaged, damaged by noise, and filtered images. The application also provides information on evaluation parameters determining the quality of filtration. This thesis also deals with testing the Non-Local Means filter on five selected sets of MR images. These sets of data were purposefully degraded by means of deterministic noises used in this thesis by means of value vector of noise parameters. This way it is possible to see and evaluate the dynamic effect of a particular noise in the context of specific MR images. This diploma thesis presents evaluation and comparison analysis of filtration for only two selected noises, including evaluation graphs and charts for one chosen data set. The last part is focused on the evaluation of multilevel OTSU segmentation between an undamaged and damaged image, and undamaged and a filtered image of two chosen areas of a human body for two chosen noises.

## Key words

MRI, types of image noise, types of image filters, convolution, Non-Local Means filter, evaluation parameters of image filtration, OTSU segmentation

# Obsah

Seznam použitých symbolů a zkratk .....	9
Seznam obrázků .....	12
Seznam tabulek .....	14
1 Úvod.....	15
2 Magnetická rezonance.....	16
2.1 Princip .....	16
2.2 Základní sekvence MR.....	16
2.2.1 Relaxační čas T1 (podélná relaxace) neboli T1 vážený obraz .....	17
2.2.2 Relaxační čas T2 (příčná relaxace) neboli T2 vážený obraz .....	17
2.2.3 Spinové echo SE.....	17
2.2.4 Gradientní echo GRE .....	18
2.2.5 Rychlé spinové echo FSE.....	18
2.3 Kontrastní látky .....	18
2.4 FID signál.....	18
2.5 Stručný princip rekonstrukce MRI obrazu .....	19
2.5.1 Rovina řezu .....	19
2.5.2 K-prostor .....	20
2.6 Artefakty .....	22
2.7 Technická konstrukce přístroje .....	23
3 Rešerše deterministických šumových generátorů, typů filtrů, obrazové konvoluce a hodnotících parametrů určujících kvalitu obrazu.....	25
3.1 Typy šumů.....	25
3.1.1 Gaussovský šum.....	25
3.1.2 Šum typu Sůl&Pepř.....	25
3.1.3 Poissonovský šum .....	26
3.1.4 Šum typu spekle .....	26
3.1.5 Šum typu Ricián.....	27
3.1.6 Ostatní typy šumů.....	27
3.2 Filtrace obrazu na základě 2D konvoluce .....	27
3.2.1 Nízkofrekvenční filtry .....	28

3.2.2	Vysokofrekvenční filtry .....	30
3.3	Hodnotící parametry kvality obrazu.....	31
3.3.1	SNR neboli odstup signálu od šumu .....	31
3.3.2	MSE neboli střední kvadratická chyba a PSNR neboli špičkový odstup signálu od šumu..	32
3.3.3	Q-index neboli univerzální index kvality .....	32
3.3.4	SSIM neboli strukturální index podobnosti.....	33
4	Analýza Non-Local Means pro filtraci MR obrazových dat .....	36
4.1	Popis vybraných obrázků .....	36
4.2	Filtrační metoda Non-Local Means.....	38
4.2.1	Princip .....	38
4.3	Softwarové prostředí pro testování Non-Local Means.....	40
4.3.1	Popis softwarové části.....	41
4.3.2	Ovládání aplikace.....	43
5	Vyhodnocení vybraných filtrovaných obrazových dat.....	54
5.1	Výsledky a srovnání vybraných testování.....	54
6	OTSU segmentace.....	63
6.1	Segmentační OTSU metoda .....	63
6.1.1	Princip OTSU metody využívající mezi-rozptyl.....	64
6.2	Vyhodnocení multilevel OTSU segmentace .....	68
7	Závěr .....	78
8	Seznam použité literatury.....	79
	Seznam příloh.....	84



## Seznam použitých symbolů a zkratek

%	Procento
$\nabla$	Laplaceův operátor
$\Sigma$	Suma
$\int$	Integrál
2D	„Dvoudimenzionální“ neboli „dvourozměrný“
3D	„Trojdimenzionální“ neboli „trojrozměrný“
$B_0$	Magnetické pole
°C	Stupeň celsia
D	Hustota – šumový parametr u šumu Sůl&Pepř a Poisson
Fe	Železo
FFT	Rychlá Fourierova transformace
FID	Radiofrekvenční signál
FSE	Rychlé spinové echo
Gd	Gadolinium
$G_F$	Gradient kódování frekvence
$G_P$	Gradient kódování fáze
GRE	Gradientní echo
$G_S$	Gradient pro výběr řezu
GUI	Grafické uživatelské rozhraní
He	Helium
MHz	Megahertz
Mn	Mangan
MRI	Magnetická rezonance
MSE	Střední kvadratická chyba
MSSIM	Výsledné kvantum lokálních strukturálních indexů podobnosti

NLM	Non-Local Means
PD	Protonová hustota
PSNR	Špičkový odstup signálu od šumu
Q-index	Univerzální index kvality
RF	Radiofrekvenční
SE	Spinové echo
SNR	Odstup signálu od šumu
SSIM	Strukturální index podobnosti
SW	Software
T	Tesla
T1	Podélná relaxace
T2	Příčná relaxace
TE	Čas signálu echa
TR	Čas repetiční
V	Rozptyl – šumový parametr u šumu Spekle, Riceovského a jeden ze dvou parametrů Gaussovského šumu
Xe	Xenon
$\alpha$	Alfa
$\beta$	Beta
$\gamma$	Gama
$\delta$	Delta
$\sigma$	Standartní odchylka
$\sigma^2$	Rozptyl – hlavní parametr NLM filtru
.jpg	Typ formátu obrázku
.png	Typ formátu obrázku
$\mu$	Střední hodnota

$\arctg$	Arkus tangens
$\text{dB}$	Decibel
$e$	Eulerovo číslo
$\text{kg}$	Kilogram
$\log$	Dekadický logaritmus
$\text{mmol}$	Milimol
$\omega_0$	Spinová frekvence

## Seznam obrázků

<b>Obrázek 1:</b> Vlevo spiny (resp. rotační osy protonů) v náhodném směru, přičemž vpravo spiny jsou rovnoběžně nasměrovány vůči siločarám působícího pole [3].....	16
<b>Obrázek 2:</b> Vlevo snímek mozku bez aplikace kontrastní látky a vpravo snímek po aplikaci kontrastní látky s lokalizací patologického místa v červeném kroužku [8] .....	18
<b>Obrázek 3:</b> Rozdíl mezi pixelem a voxelem [10] .....	20
<b>Obrázek 4:</b> Vznik pruhu voxelů na místě 2D obrazu [10].....	21
<b>Obrázek 5:</b> K-prostor [10] .....	22
<b>Obrázek 6:</b> Překrývání horizontálního a vertikálního pruhu [10].....	22
<b>Obrázek 7:</b> Výsledný vznik obrazu [10].....	22
<b>Obrázek 8:</b> Pohybový artefakt na výsledném MRI obraze [6] .....	23
<b>Obrázek 9:</b> Příklad matice obrázku 3×3 [13].....	26
<b>Obrázek 10:</b> Příklad konvoluce [19].....	28
<b>Obrázek 11:</b> Vlevo zobrazení konvoluční matice o rozměrech 3×3, následně zjištění mediánu a nahrazení původní hodnoty novou [23] .....	30
<b>Obrázek 12:</b> Ukázka obrázků z oblasti kolenní chrupavky. Zdroj vedoucí diplomové práce. ....	36
<b>Obrázek 13:</b> Ukázka obrázků z oblasti dělohy [35].....	37
<b>Obrázek 14:</b> Ukázka obrázků z oblasti mozku [36].....	37
<b>Obrázek 15:</b> Ukázka obrázků z oblasti prostaty [37].....	37
<b>Obrázek 16:</b> Ukázka obrázků z oblasti ženských prsou [38].....	38
<b>Obrázek 17:</b> Porovnávání podobnosti mezi pixelem p vůči q1 a q2. Zdroj vedoucí diplomové práce, přičemž obrázek byl upraven. ....	39
<b>Obrázek 18:</b> Grafické uživatelské rozhraní aplikace NLM_filter s ukázkou filtrace pro Sůl&Pepř šum. Zdroj vlastní. ....	44
<b>Obrázek 19:</b> Grafické uživatelské rozhraní aplikace NLM_filter s ukázkou filtrace pro Poisson šum. Zdroj vlastní .....	45
<b>Obrázek 20:</b> Grafické uživatelské rozhraní aplikace NLM_filter s ukázkou filtrace pro šum Ricián. Zdroj vlastní .....	45
<b>Obrázek 21:</b> Dialogové okno. Zdroj vlastní.....	46
<b>Obrázek 22:</b> Varovné okno v případě výběru neexistujícího šumu. Zdroj vlastní. ....	47
<b>Obrázek 23:</b> Okno ukazující průběh filtrace. Zdroj vlastní. ....	47
<b>Obrázek 24:</b> Ukázka log_file souboru. Zdroj vlastní.....	48
<b>Obrázek 25:</b> Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami $M = 0,5$ a $V = 0,5$ ; šumem Sůl&Pepř s hodnotou $D = 0,5$ ; Poissonovským šumem s hodnotou $D = 0,5$ ; Spekle šumem s hodnotou $V = 0,5$ a šum Ricián s hodnotou $V = 0,5$ . Zdroj originálního obrázku vedoucí diplomové práce, ostatní od něj převzaty a upraveny. ....	49
<b>Obrázek 26:</b> Výsledek filtrace zašuměných obrázků uvedených v obrázku 25 s hodnotou $\sigma^2 = 1$ . Zdroj obrázků vedoucí diplomové práce, přičemž byly upraveny. ....	49
<b>Obrázek 27:</b> Výsledek filtrace zašuměných obrázků uvedených v obrázku 25 s hodnotou $\sigma^2 = 0,1$ . Zdroj obrázků vedoucí diplomové práce, přičemž byly upraveny. ....	50

<b>Obrázek 28:</b> Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami $M = 0,2$ a $V = 0,2$ ; šumem Sůl&Pepř s hodnotou $D = 0,2$ ; Poissonovským šumem s hodnotou $D = 0,2$ ; Spekle šumem s hodnotou $V = 0,2$ a šum Ricián s hodnotou $V = 0,2$ . Zdroj originálního obrázku [36], ostatní převzaty z [36] a upraveny.	50
<b>Obrázek 29:</b> Výsledek filtrace zašuměných obrázků uvedených v obrázku 28 s hodnotou $\sigma^2 = 0,35$ . Obrázky převzaty z [36], přičemž byly upraveny.	51
<b>Obrázek 30:</b> Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami $M = 0,45$ a $V = 0,45$ ; šumem Sůl&Pepř s hodnotou $D = 0,45$ ; Poissonovským šumem s hodnotou $D = 45$ ; Spekle šumem s hodnotou $V = 0,45$ a šum Ricián s hodnotou $V = 0,45$ . Zdroj originálního obrázku [36], ostatní převzaty z [36] a upraveny.	51
<b>Obrázek 31:</b> Výsledek filtrace zašuměných obrázků uvedených v obrázku 30 s hodnotou $\sigma^2 = 0,35$ . Obrázky převzaty z [36], přičemž byly upraveny.	52
<b>Obrázek 32:</b> Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami $M = 0$ a $V = 0,3$ ; šumem Sůl&Pepř s hodnotou $D = 0,25$ ; Poissonovským šumem s hodnotou $D = 0,35$ ; Spekle šumem s hodnotou $V = 0,6$ a šum Ricián s hodnotou $V = 0,1$ . Zdroj originálního obrázku [37], ostatní převzaty z [37] a upraveny.	52
<b>Obrázek 33:</b> Výsledek filtrace zašuměných obrázků uvedených v obrázku 32 s hodnotou $\sigma^2 = 0,8$ . Obrázky převzaty z [37], přičemž byly upraveny.	53
<b>Obrázek 34:</b> Srovnání průběhu výsledných hodnot hodnotícího parametru SSIM pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.	59
<b>Obrázek 35:</b> Srovnání průběhu výsledných hodnot hodnotícího parametru SNR pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.	60
<b>Obrázek 36:</b> Srovnání průběhu výsledných hodnot hodnotícího parametru PSNR pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.	60
<b>Obrázek 37:</b> Srovnání průběhu výsledných hodnot hodnotícího parametru MSE pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.	61
<b>Obrázek 38:</b> Srovnání průběhu výsledných hodnot hodnotícího parametru SNR pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.	62
<b>Obrázek 39:</b> Testovaný obrázek s jeho histogramem [44]	64
<b>Obrázek 40:</b> Výpočet váhy a průměrné intenzity pro pozadí testovaného obrázku. Převzato a upraveno z [44]	65
<b>Obrázek 41:</b> Příklad analogického výpočtu průměrné hodnoty intenzity a váhy pro popředí obrázku. Převzato a upraveno z [44]	65
<b>Obrázek 42:</b> Srovnání testovaného obrázku a obrázku po jeho segmentaci [44]	65
<b>Obrázek 43:</b> Vývojový diagram algoritmu pro multilevel OTSU metodu. Převzato a upraveno z [44]	66
<b>Obrázek 44:</b> Vlevo originální obrázek a napravo tentýž obrázek po segmentaci klasickou OTSU metodou [44]	66
<b>Obrázek 45:</b> Vývojový diagram algoritmu pro multilevel OTSU metodu. Převzato a upraveno [44]	67
<b>Obrázek 46:</b> Vlevo v horní řadě nativní obrázek, následně dva obrázky po filtraci, kdy byly poškozeny šumem Ricián s hodnotami $V = 0,1$ a $V = 0,3$ . Pod nimi jejich segmentace pro úroveň segmentační třídy 3. Zdroj nativního obrázku [36], ostatní převzaty z [36] a upraveny.	68

<b>Obrázek 47:</b> Vlevo v horní řadě nativní obrázek, následné dva obrázky po zašumění Sůl&Pepř šumem s hodnotami $D = 0,1$ a $D = 0,5$ . Pod nimi jejich segmentace pro úroveň seg. třídy 8. Zdroj nativního obrázku [37], ostatní převzaty z [37] a upraveny.....	69
<b>Obrázek 48:</b> Hodnoty SSIM pro oblast mozku. Zdroj vlastní. ....	74
<b>Obrázek 49:</b> hodnoty SSIM pro oblast prostaty. Zdroj vlastní. ....	75
<b>Obrázek 50:</b> Hodnoty SNR pro oblast mozku. Zdroj vlastní.....	75
<b>Obrázek 51:</b> Hodnoty SNR pro oblast prostaty. Zdroj vlastní.....	76
<b>Obrázek 52:</b> Hodnoty MSE pro oblast mozku. Zdroj vlastní. ....	77
<b>Obrázek 53:</b> Hodnoty MSE pro oblast prostaty. Zdroj vlastní. ....	77

## Seznam tabulek

<b>Tabulka 1:</b> Informace o vybraných obrazových data setech [vedoucí diplomové práce, 35, 36, 37, 38]...	36
<b>Tabulka 2:</b> Shrnující tabulka výsledků filtrace při nastavení $\sigma^2 = 0,1$ .....	55
<b>Tabulka 3:</b> Shrnující tabulka výsledků filtrace při nastavení $\sigma^2 = 0,5$ .....	56
<b>Tabulka 4:</b> Shrnující tabulka výsledků filtrace při nastavení $\sigma^2 = 0,8$ .....	56
<b>Tabulka 5:</b> Shrnující tabulka výsledků filtrace při nastavení $\sigma^2 = 0,1$ .....	57
<b>Tabulka 6:</b> Shrnující tabulka výsledků filtrace při nastavení $\sigma^2 = 0,5$ .....	58
<b>Tabulka 7:</b> Shrnující tabulka výsledků filtrace při nastavení $\sigma^2 = 0,8$ .....	58
<b>Tabulka 8:</b> Tabulka výsledků segmentace pro Riceovský šum (mozek) .....	70
<b>Tabulka 9:</b> Tabulka výsledků segmentace pro Riceovský šum (prostata).....	71
<b>Tabulka 10:</b> Tabulka výsledků segmentace pro Sůl&Pepř šum (mozek) .....	72
<b>Tabulka 11:</b> Tabulka výsledků segmentace pro Sůl&Pepř šum (prostata) .....	73

# 1 Úvod

Cílem práce je filtrace obrazových dat, získaných z magnetické rezonance, pomocí Non-Local Means metody a jejich následné vyhodnocení. Všeobecně je filtrace obrazu používána pro dosažení jeho lepší kvality, a to odstraněním šumu, který představuje nežádoucí aditivní informaci v obraze. Většina filtrů spadá do skupiny tzv. Local-Means filtrů, které lze dále dělit na vysokofrekvenční a nízkofrekvenční. Vysokofrekvenční filtry slouží pro zvýraznění hran (např. Laplaceův a Sobelův filtr) a nízkofrekvenční pro odstranění šumu (Průměrový, Gaussův a Mediánový filtr). Pomyslnou druhou skupinu tvoří jediný tzv. Non-Local Means filtr, který se vyznačuje svým specifickým použitím pro odstranění Riceovského šumu. Tímto šumem jsou nejčastěji poškozeny obrazová data získaná z magnetické rezonance. Filtrace Non-Local means metodou se v této práci soustředí na filtrační parametr Gaussovského rozložení okolí pixelu.

Pro účely testování filtrace byla vytvořena softwarová aplikace, která umožňuje použití Non-Local Means filtru na šumem degradovaná data. Následně aplikace zprostředkovává uživateli informace o jednotlivých parametrech, jako je např. SSIM a SNR, které určují kvalitu provedené filtrace, tudíž kvalitu výsledného obrazu.

Teoretická část je zaměřena především na popis principu fungování magnetické rezonance, její základní sekvence, technickou konstrukci přístroje, ale i na popis rekonstrukce obrazů.

Jako součást práce byla zpracována i rešerše, která je věnována tématice deterministických šumových generátorů, typu filtrů, obrazové konvoluce a hodnotících parametrů určujících kvalitu obrazu.

Úvod do praktické části tvoří kapitola, která se zabývá popisem konkrétních obrazových dat MR a detailním vysvětlením principu použité Non-Local Means filtrační metody. Dále se diplomová práce věnuje podrobnému popisu jednotlivých funkcí vytvořené softwarové aplikace a její ovládání uživatelem. Následovně se text zabývá vyhodnocením filtrovaných obrazových dat získaných pomocí výše zmíněné Non-Local Means metody. Evaluace spočívá v porovnání výsledných parametrů mezi originálními a filtrovanými obrázky.


Separátní úlohou je vyhodnocení multilevel OTSU segmentace, jež byla použita pro následnou komparaci mezi originálním a zašuměným obrázkem a originálním a filtrovaným obrázkem.

## 2 Magnetická rezonance

Magnetická rezonance neboli *MR* (z *angl. Magnetic Resonance*) je neinvazivní zobrazovací metoda, která je využívána k zobrazování jednotlivých tkáňových struktur, přičemž se nepoužívá ionizační záření. Patří mezi nejcitlivější metody k vyhodnocení morfologie a patologie měkkých tkání. [1]

### 2.1 Princip

Je založen na analýze magnetických momentů atomových jader, která využívá přítomnosti atomů vodíku. V lidském organismu jsou atomy vodíku obsaženy ze 2/3. Pokud začneme působit elektromagnetickým polem na organismus, docílíme tím vychýlení jádra atomu, které je složeno z nukleonů (neutronů a protonů) z rovnovážného stavu. Přestaneme-li působit elektromagnetickým polem, vrátí se jádra atomu zpět do rovnovážného stavu o různých rychlostech a dochází ke vzniku rezonančního signálu. Tímto donutíme protony rotovat kolem své vlastní osy. Tento pohyb je označován jako spin, přičemž působení elektromagnetického pole má za následek rovnoběžné nasměrování jednotlivých spinů (resp. rotačních os protonů) vůči siločávkám působícího pole. To znamená, že všechny protony mají souhlasně orientované magnetické momenty (paralelně). V situaci, kdy nedochází k působení magnetického pole z vnějšího zdroje, jsou rotační osy protonů náhodné. Rezonanční signál se odvíjí od relaxačních časů *T1* a *T2* a *PD* (z *angl. Proton Density, Protonová hustota*). Na obrázku 1 je znázornění změny rotační osy protonů. [2, 3, 4, 5, 6]



**Obrázek 1:** Vlevo spiny (resp. rotační osy protonů) v náhodném směru, přičemž vpravo spiny jsou rovnoběžně nasměrovány vůči siločárám působícího pole [3]

### 2.2 Základní sekvence MR

S ukončením vlivů magnetického pole dochází k návratu systému do původního ustáleného stavu a tato doba návratu se označuje jako relaxace, přičemž opětovně dochází ke vzniku náhodných rotačních os protonů. Mezi základní sekvence *MR* patří *T1* a *T2* relaxační časy, spinové echo *SE*, gradientní echo *GRE* a rychlé spinové echo *FSE*. Je ale důležité si uvědomit, že relaxační časy *T1* a *T2* nejsou totožné pro jednotlivé tkáně, tudíž kvůli rozdílu v intenzitách signálu vznikne rozdíl ve stupni šedi na obrazovce. Obecně řečeno, relaxačními časy zjistíme charakterizaci chemické struktury tkáně, kdy pro nádorovou a zdravou tkáň jsou



odlišné. Slovem sekvence se to označuje proto, že vyšetřovaná oblast je vystavována vlivům magnetického pole opakovaně do doby, dokud se nezajistí dostatečně kvalitní obraz.

Níže jsou vysvětleny pojmy k lepšímu pochopení podkapitoly 2.2

- **Čas TE (čas signálu echa):** Jedná se o čas, který je mezi pulsem excitačním a detekcí rezonančního signálu.
- **Čas TR (čas repetiční):** Je dobou, během níž dochází k opakované aplikaci excitačních pulsů, kdy při zkracujícím se času  $TR$  je také  $T1$  kratší.
- **Sklápěcí úhel  $\alpha$ :** Představuje použitou energii na radiofrekvenční excitační puls, a se vzrůstající vyzařenou energií roste čas potřebný k plné relaxaci.

[3, 5, 7]

### 2.2.1 Relaxační čas $T1$ (podélná relaxace) neboli $T1$ vážený obraz

Nazýván také spin-mřížkový relaxační čas, vyjadřuje zachycení rychlosti, odevzdávané energie vychýleného jádra při relaxaci elektromagnetickým vlnám a okolnímu prostředí. Dochází k obnově 63 % podélné magnetizace. Rychlost se odvíjí od viskozity prostředí, teploty a koncentrace jader, kdy s klesající teplotou roste a se vzrůstajícím magnetickým polem  $B_0$  klesá. Je důležité podotknout, že se relaxační čas  $T1$  u různých tkání lidského organismu liší. Nejdelší je u tkání s největším obsahem vody, pro parenchymatické orgány je středně dlouhá a tkáň tuková má nejkratší čas.

[3, 5]

### 2.2.2 Relaxační čas $T2$ (příčná relaxace) neboli $T2$ vážený obraz

Nazýván také spin-spinový relaxační čas, kdy na základě vzájemného působení mezi spiny jednotlivých jader nastává defázování precesního pohybu magnetických momentů, kdy v jeho průběhu dojde ke ztrátě 63 % příčné magnetizace. Relaxační čas  $T2$  se opět liší pro jednotlivé tkáně. Tkáně s vysokým obsahem vody mají dlouhý čas, tkáň tuková středně dlouhý a parenchymatické orgány krátký čas.

[3, 5]

### 2.2.3 Spinové echo SE

Je složeno z páru radiofrekvenčních pulzů o sklápěcím úhlu  $\alpha$   $90^\circ$  a  $180^\circ$  a je používáno pouze k tvorbě  $T1$  váženého obrazu. Vysláním  $90^\circ$  pulzu zapříčiníme nárůst vektoru příčné magnetizace, který začne klesat s ukončením jeho trvání. Poté je vyslán  $180^\circ$  pulz v čase  $TE/2$ , což způsobuje, že protony s původně rychlým precesním pohybem proniknou za protony s pomalejším precesním pohybem, přičemž vektor příčné magnetizace, který se zmenšuje, opětovně dosahuje velikosti. Jakmile uplyne další  $TE/2$  čas, nastává synchronizace pohybu protonů, což způsobí opětovnou maximalizaci  $FID$  signálu (z angl. *Free Induction Decay*), který lze zaznamenat. Sečteme-li oba  $TE/2$  časy, zjistíme  $TE$ .

[5, 7]

## 2.2.4 Gradientní echo GRE


K jeho vytvoření se používá gradientní magnetické pole, které zapříčiní u vyšetřované tkáně navýšení magnetické nehomogenity. To má za následek rychle ztrácející se příčnou magnetizaci a u rotujících protonů rychlejší ztrátu jejich synchronního pohybu. Poté je s opačnou orientací opětovně aplikován, a kvůli opačné orientaci vzniká opačný účinek. Dochází vlastně k resynchronizaci pohybu rotujících protonů a zvyšování příčné magnetizace na nejvyšší hodnotu. Takto vzniká gradientní echo *GRE*. [5]

## 2.2.5 Rychlé spinové echo FSE

Jedná se o rychlejší způsob *SE*, kdy dochází k vícečetnému použití spinových ech. Díky tomu je urychlena doba měření ve srovnání s „obyčejnou“ *SE* a používá se k tvorbě *T2* váženého obrazu. [5, 7]

## 2.3 Kontrastní látky

Jejich funkce je zesílení naměřeného signálu a také ovlivňují relaxační časy *T1* a *T2*. Používají se hlavně paramagnetické látky. Mezi ně patří sloučeniny železa *Fe*, Gadolinia *Gd*, Manganu *Mn*, polarizované plyny helia *He* a xenonu *Xe* apod. Relaxační čas *T1* je ovlivněn o cca desítky % a *T2* cca o jednotky %. Jednotka dávky je *mmol* a běžně se aplikuje 0,1 – 0,2 *mmol/kg* jak pro dospělé, tak pro děti. Kontrastní látky k tomuto účelu jsou vylučované ledvinami, respektive nefrotropní. Na obrázku 2 jsou dva *MRI* snímky, přičemž jeden byl pořízen bez aplikace kontrastní látky a druhý po její aplikaci. [4, 8]



**Obrázek 2:** Vlevo snímek mozku bez aplikace kontrastní látky a vpravo snímek po aplikaci kontrastní látky s lokalizací patologického místa v červeném kroužku [8]

## 2.4 FID signál

Je nezbytné použít radiofrekvenční pulz na vyšetřovanou oblast kromě hlavního magnetického pole (od něho se odvíjí frekvence signálu). Tím se vektor podélné magnetizace překlápí na vektor magnetizace příčné a vzniká volně indukovaný signál, *FID* signál, který je při použití *MRI* zaznamenáván. Časováním a pořadím radiofrekvenčních pulzů lze tento signál formovat, a taktéž *MRI* obraz, kdy jeho síla je určována velikostí relaxačních časů *T1* a *T2* a je přímo úměrná množství rezonujících jader excitovaných atomů. Jeho frekvence se pohybuje v rozmezí jednotek až desítek *MHz*. Samotný signál reprezentuje uvolňování

elektromagnetického vlnění na frekvenci, která je pro jádra atomů, tomuto signálu vystavená, charakteristická. [5, 9]

## 2.5 Stručný princip rekonstrukce MRI obrazu

Využívá matematického algoritmu Rychlé Fourierovy Transformace *FFT* (z *angl. Fast Fourier Transformation*), kdy z odlišných částí těla dochází k lokalizaci *MRI* signálu. Jeho použitím je možno tvořit *2D* nebo *3D* obrazy s rozdílným rozlišením a velikostí. Jeho kvalita se odvíjí od vnějších a vnitřních podmínek a hodnotí se na základě kontrastu a prostorového rozlišení detailů. Mezi vnější podmínky patří čas relaxace apod.; naopak mezi vnitřní patří *PD*, rozdílné relaxační časy *TR* tkání apod. Nutno podotknout, že intenzita signálu je tím větší, čím je větší počet protonů v jednotce objemu. [4]

### 2.5.1 Rovina řezu

Hlavní podstatou pro úspěšnou rekonstrukci *MRI* obrazu je prostorové rozdělení signálů z *MRI*, které následně reflektují strukturu příslušné tkáně či tkání. Obvykle se k tomu používá metoda, která prostorově mění magnetické pole.

Pomocí *MRI* lze zobrazit části lidského těla v různých rovinách řezu, čehož dosáhneme přepínáním *gradientu* (tím prostorově měníme magnetické pole). *Gradient* je změna magnetického pole v určitém směru, kdy *gradient* je tvořen, protéká-li elektrický proud cívku nebo kruhovým vodičem. Změní-li se směr protékajícího proudu, nastává změna magnetického pole. Přístroj pro *MRI* má párové gradientní cívky ve směru *x*, *y* a *z* osy. Protéká jimi proud o stejné velikosti, ale s jinou polaritou. Jedna cívka má za úkol zvyšování statického magnetického pole, protějščí ho snižuje.

V okolí normálního magnetického pole je jeho síla  $B_0$  všude stejná. Z toho důvodu je spinová frekvence  $\omega_0$  všude totožná úměrně velikosti magnetického pole. Použitím *gradientu* ale dochází k lineárnímu nárůstu magnetického pole. Takto dochází ke vzniku různých spinových frekvencí  $\omega_0$ . Někde je pomalejší a někde naopak rychlejší. Ve výsledku ukazují různou rezonanční frekvenci.


Další neméně důležitou částí je určování pozice řezu. Pro příklad použijme řez v rovině *xy*, která je kolmá k rovině *z*. Leží-li pacient na zádech nebo je jeho pozice nakloněná podél osy *z*, získáváme transversální rovinu obrazu. Za účelem výběru roviny je současně přepnut *gradient* ve směru roviny *z* (tzv. *z-gradient*) k *RF* signálu. Tento gradient je označován jako  $G_s$  (z *angl. Slice-Selection Gradient*) *gradient* neboli *gradient* pro výběr řezu. Magnetické pole má původní velikost  $B_0$  pouze v jedné pozici  $z_0$ . Pokud by *RF* signál obsahoval pouze jednu frekvenci  $\omega_0$ , docházelo by k vyvolání spinů pouze v rezonanční oblasti  $z_0$ , a tím výběru pozice řezu, kdy tloušťka řezu je určena rezonanční oblastí spinu.

Pro výběr sagitálního řezu přepínáme *x-gradient*, pro koronární řez *y-gradient*. Chceme-li ale získat šikmý řez, musíme *gradients* různě kombinovat. [10]

## 2.5.2 K-prostor

V této podkapitole se budeme zabývat tím, jak se získá výsledný obraz z řezu. Je důležité si uvědomit, že obraz není generován přímo z měření, ale prvně jsou získána tzv. *RAW DATA*, z kterých je obraz vytvořen.

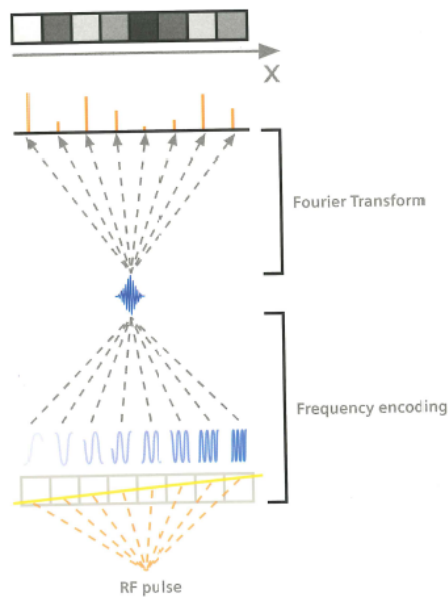
*MRI* obraz je složen z mnoha elementů, tzv. pixelů. Obraz je tudíž v podstatě obrazová matice, kdy každý pixel má určitou hodnotu stupně šedi. Dohromady nám pixely dávají výsledný obraz a *pixel* v obraze představuje *voxel* v řezu. Čím je více *pixelů/voxelů*, tím vyšší kvality obraz je. Na obrázku 3 je vidět rozdíl mezi *pixel*em a *voxel*em.



Obrázek 3: Rozdíl mezi pixel a voxel [10]

Výzvou je, jak získat zvlášť pro každý jednotlivý voxel z řezu informaci o signálu, která generuje určitou hodnotu stupně šedi příslušnému pixelu. Řekněme, že chceme vytvořit tomogram o velikosti matice  $256 \times 256$ . To znamená, že každý řádek a sloupec musí být rozdělen na 256 míst. Chceme tudíž vytvořit *MRI* obraz s 256 různými hodnotami, což ve výsledku znamená 65,536 *voxelů*. Jak toho dosáhneme, je vysvětleno níže.


Pro zjednodušení budu popisovat vznik pruhu *voxelů* na místě 2D obrazu. Pruh bude složen z 256 *voxelů* a půjde podél osy  $x$ . V průběhu měření *echa* zaměříme *gradient* ve směru osy  $x$ , což způsobí nárůst spinu *voxelů* podél osy  $x$  s rostoucí frekvencí. Tento proces je znám jako frekvenční kódování a příslušný *gradient* jako *gradient* kódování frekvence  $G_F$  (z angl. *Frequency-Encoding Gradient*). *Echo* je tudíž soubor signálů všech excitovaných spinů podél osy  $x$ . Při rozlišení 256 *voxelů* je *echo* složeno z 256 různých frekvencí, respektive zvuku, který obsahuje 256 různých tónů. Pomocí *FFT* určíme přínos (resp. informaci) každé jednotlivé frekvence (resp. každého jednotlivého tónu). Poté jsou jednotlivé frekvence znovu přiděleny na jejich původní místo na ose  $x$ . Podstatnou myšlenkou je, že každý jednotlivý signál, který je zachycen, určuje hodnotu stupně šedi příslušnému pixelu (resp. jednotlivé signály reprezentují jednotlivé pixely). Obrázek 4 znázorňuje výše popsany princip.



**Obrázek 4:** Vznik pruhu voxelů na místě 2D obrazu [10]

S tímto bychom si vystačili, pokud bychom chtěli pouze jeden pruh. Je důležité podotknout, že stejný postup ve směru osy  $y$  nelze použít, jelikož dva různé *voxely* by mohly mít stejnou frekvenci, proto by nemohly být rozlišeny. Způsob je takový, že během času *RF* pulsu a *echa* dojde ke krátkému přepnutí *gradientu* ve směru osy  $y$ . Ve výsledku budou mít spiny po krátkou dobu různé rychlosti. Poté, co je *gradient* vypnut, budou mít spiny podél osy  $y$  různý fázový posun, který je přímo úměrný jejich umístění. Proces je nazván jako fázové kódování a příslušný *gradient* jako *gradient* kódování fáze  $G_P$  (*z angl. Phase-Encoding Gradient*). Opětovně lze použít *FFT* k filtraci těchto fázových posunů. Je ale nutno podotknout, že tohle lze pouze tehdy, pokud generujeme *MRI* obraz o 256 signálech s různým fázovým kódováním pro 256 různých míst. Jinými slovy, to znamená 256 kroků pro fázové kódování. Proto je nezbytné, aby tato sekvence byla zopakována 256krát pro matici o velikosti  $256 \times 256$ . Takto tzv. *RAW DATA* spolu s *echy* vyplňují řádek po řádku. Tato *RAW DATA* jsou známa také pod pojmem *K-prostor*.

Osy  $k_x$  a  $k_y$  *k-prostoru* označují tzv. *prostorové frekvence*. Stejně jako dočasné oscilace kombinují vlny o různých frekvencích, tak lze vytvořit obraz ze vzorů prostorových pruhů. Hodnota *RAW DATA* v *K-prostoru* určuje, zda a do jaké míry určitý vzor pruhu přispívá k celkovému obrazu. Hrubý vzor pruhu má malou prostorovou frekvenci blízko středu, přičemž jemný vzor má vysokou prostorovou frekvenci dále od středu. Znázorněno na obrázku 5.




**Obrázek 5:** K-prostor [10]

Pomocí jednoduchého překrývání horizontálního a vertikálního pruhu lze vytvořit komplexní vzor hodnoty šedé; znázorněno na obrázku 6. Následně pomocí vážené superpozice jednotlivých pruhových vzorů s různými prostorovými frekvencemi vznikne výsledný obraz; znázorněno na obrázku 7.



**Obrázek 6:** Překrývání horizontálního a vertikálního pruhu [10]



**Obrázek 7:** Výsledný vznik obrazu [10]

Vše, co je výše popsáno, je prací *2D FFT*. Používá hodnoty *RAW DAT* v *K-prostoru* k výpočtu hodnoty stupně šedi distribuce obrazu, což je již zmíněné vážení pruhů. Následně přiřazuje hodnoty stupně šedi příslušným pixelům. [10]

## 2.6 Artefakty

Artefakty jsou příčinou snížení kvality, což snižuje výpovědní hodnoty obrazů. Lze je popsat jako signálovou intenzitu, která není souhlasná se skutečnou prostorovou distribucí tkání. Vzniku některých

artefaktů lze zcela předejít, některé můžeme částečně kontrolovat a některé nelze kontrolovat vůbec. Rozlišujeme tedy dvě skupiny artefaktů, první skupinou jsou kontrolovatelné artefakty (ať už zcela nebo částečně) a druhou jsou artefakty, které nelze jakkoliv kontrolovat. Na obrázku 8 je vidět, jak vypadá MRI snímek pořízený během pohybového artefaktu. [6]



Obrázek 8: Pohybový artefakt na výsledném MRI obraze [6]

## 2.7 Technická konstrukce přístroje

Jádrem je řídicí počítač, který zajišťuje interakci s přístrojem, respektive zajišťuje všechny procesy vyšetření a užitím *FFT* v reálném čase rekonstruuje sérii snímků vyšetřovaných řezů (resp. místa vyšetření). Ústřední jednotkou je magnet s dostatečným výkonem, jenž vytváří homogenní magnetické pole. Lze užít tři typy magnetů na základě žádané intenzity magnetického pole, a to odporové, supravodivé a permanentní.

- **Odporové magnety:** Jejich vodiči protéká elektrický proud, čímž dochází k indukci magnetického pole, tudíž využívají elektromagnetický princip. Průchodem proudu dochází k zahřívání magnetů, proto je nutné, aby byly chlazeny. Využívají se pro práci s intenzitou do  $0,5\ T$ . Navzdory tomu, že náklady na chlazení jsou nižší v porovnání se supravodivými magnety, samostatný provoz vyžaduje vysoké množství energie.
- **Supravodivé magnety** využívají kapalné hélium k dosažení teploty okolo  $-270\ ^\circ\text{C}$ , které je nutné pro vyvolání supravodivosti. Umožňují pracovat v rozmezí intenzit  $0,3 - 4\ T$ , čímž také dosahují vysokých rozlišovacích schopností, a to kompenzuje jejich nákladovost.
- **Permanentní magnety:** Pracují s intenzitou do  $0,3\ T$ , proto není možné jimi dosáhnout rozlišovací schopnosti na takové úrovni jako se dvěma výše uvedenými. Dosahují ale lepšího tkáňového kontrastu, jenže mají velkou hmotnost, což je kompenzováno příznivou pořizovací cenou.

Mezi další neméně důležitou část patří radiofrekvenční cívky *RF*, zastupující roli antény vysílající elektromagnetický signál, a také slouží jako modifikátory magnetického pole v zamyšleném místě *MRI*. Dle funkce se dělí na povrchové, gradientní, vyrovnávací a objemové cívky.

- **Povrchové cívky:** Mají tvar podle vyšetřované části, kde se také přikládají. Zastupují funkci přijímací antény signálů pocházející z vyšetřované oblasti. Pojmenování mají podle místa vyšetření, ke kterému jsou určeny. Například páteřní, hlavová apod. Kvůli tomu, že je signál zachycován v blízkosti, dochází ke zlepšení poměru signál/šum a také kvality jeho zobrazení.
- **Gradientní cívky:** Získáváme jimi prostorovou informaci o rozložení a rysech protonů ve vyšetřované oblasti, a to tím, že jejich funkcí je tvorba přídatných magnetických polí – gradientů. Jejich činnost je doprovázena hlukem, který je při vyšetření *MRI* přístrojem typický.
- **Vyrovnávací cívky:** Aby bylo dosaženo kvalitního zobrazení vyšetřované oblasti, je nutné dosáhnout bezchybné homogenity použitého magnetického pole, a to je právě funkcí těchto cívek, které vyrovnávají nehomogenity v magnetickém poli, jež je vytvářeno daným *MRI* přístrojem.
- **Objemové cívky:** Jejich funkcí je vysílání elektromagnetických pulsů, které excitují protony z paralelního do antiparalelního stavu pozice a jsou pevnou součástí vyšetřovací části přístroje, která kompletně obklopuje pacienta. Rovněž se dá použít k přijímání signálů z vyšetřovaných oblastí o velkém objemu.

Gradientní, vyrovnávací a objemové cívky se nacházejí za stěnou tunelu, ve kterém je pacient uložen, a proto jediná možnost, kdy je lze zpozorovat, je v situaci demontáže *MRI* přístroje. [2, 6]



### 3 Rešerše deterministických šumových generátorů, typů filtrů, obrazové konvoluce a hodnotících parametrů určujících kvalitu obrazu

Cílem rešerše je poskytnout informace o nejčastějších typech šumu, filtračních metodách a hodnotících parametrech obrazu.

#### 3.1 Typy šumů

Nejprve si definujeme šum. Šum představuje aditivní informaci v obrazu, která je nahodilého původu. Může vznikat při zpracování, umělým přidáním, na senzoru zařízení, které pořizuje obraz apod. V konečném důsledku znehodnocuje obrazovou informaci.

Veškeré obrazové příklady šumů jsou uvedeny v praktické části. [11, 12]

##### 3.1.1 Gaussovský šum

Gaussovský šum (*angl. Gaussian Noise*) je nejčastějším typem šumu. Vyznačuje se normálním rozložením, což znamená, že všechny pixely jsou poškozeny stejnou mírou šumu (resp. zasažené pixely jsou poškozeny stejnou intenzitou stupně šedi, která se pohybuje v rozmezí 0 až 256), což znamená, že míra šumu nezávisí na hodnotách pixelu. Jeho původcem jsou přírodní zdroje, jako je tepelná vibrace atomů apod. Dá se popsat následující rovnicí: [13]

$$P(g) = \sqrt{\frac{1}{2\pi\sigma^2}} e^{-\frac{(g-\mu)^2}{2\sigma^2}} \quad (1)$$

Kde  $g$  je hodnota stupně šedi,  $\sigma$  představuje standardní odchylku a  $\mu$  střední hodnotu. [11, 12, 13]

##### 3.1.2 Šum typu Sůl&Pepeř

Šum typu Sůl&Pepeř (*angl. Salt&Pepper noise*) způsobí, že poškozený obrázek bude obsahovat černé pixely ve světlých oblastech a světlé pixely v tmavých oblastech. Respektive šum bude mít hodnotu 0 (černá), 255 (bílá). Všechny pixely ale poškozené nejsou, přičemž množství poškozených pixelů závisí na tom, do jaké míry je obrázek zasažen.

Představme si matici obrazu  $3 \times 3$ , která je znázorněna na obrázku 9. Lze vidět, že došlo ke změně hodnoty prostředního pixelu, který byl poškozen tímto šumem. V tomto případě se hodnota prostředního pixelu změnila na 0, tudíž pixel takzvaně zčerná.

Vzniká při přenosu dat, při převodu analogového obrázku na digitální apod.

254	207	210		254	207	210
97	212	32	→	97	0	32
62	106	202		62	106	202

**Obrázek 9:** Příklad matice obrázku 3×3 [13]

Lze jej popsat následující rovnicí: [13]

$$P(g) = \begin{cases} Pa & \text{pro } g = a \\ Pb & \text{pro } g = b \\ 0 & \text{jinak} \end{cases} \quad (2)$$

Kde  $g$  opět představuje stupeň šedi (tentokrát 0 nebo 255),  $a$  představuje světlou oblast,  $b$  představuje tmavou oblast a číslo 0 znamená, že pixel nebyl poškozen. [13, 14]

### 3.1.3 Poissonovský šum

Poissonovský šum (*angl. Poisson Noise*) závisí na obrazových datech a je také označován jako *Photon Noise*. Jedná se o typ elektronického šumu, který vzniká v případě, kdy konečný počet částic (jako elektrony v elektronickém obvodu nebo v optickém zařízení fotony) přenášející energii je natolik malý, že způsobí zjistitelnou fluktuaci v měření. [14, 15]

### 3.1.4 Šum typu spekle

Tento typ šumu (*angl. Speckle Noise*) vypadá jako granulovaná textura (zvyšuje průměrnou úroveň šedé v zasažené oblasti) a je přítomný v radarovém zobrazení, v laserových systémech, v ultrazvukových snímcích (typu B mód snižuje jeho kontrast a rozlišení) apod.; respektive je vidět v koherentním zobrazovacím systému. Může být považován za nežádoucí vlastnost (ne vždy tomu tak je), jelikož skrývá sice malé, ale diagnosticky podstatné rysy v obrázcích, a je způsoben chybným přenosem dat. Není nahodilým elektrickým šumem, ale odvíjí se podle nastavení snímače nebo podle struktury tkáně (v případě použití ultrazvuku v medicíně). Lze jej popsat následující rovnicí: [12]

$$J = I + n * I \quad (3)$$

Kde  $I$  je vstupní obraz,  $J$  je rozložení šumu v obraze a  $n$  znamená jednotnou nulovou střední hodnotu šumu v obraze a rozptyl  $v$ . [13, 15, 16]

### 3.1.5 Šum typu Ricián

Snímky z *MRI* jsou nejčastěji poškozeny tímto šumem, který vzniká z komplexního *Gaussova* šumu, a to tak, jestli je reálná a imaginární část signálu poškozena nekorelovatelnou nulovou střední hodnotou *Gaussova* šumu. Velikost signálu může být vyjádřena následujícím vzorcem: [18]

$$M = \sqrt{(A + n_1)^2 + n_2^2} \quad (4)$$

Kde  $M$  je velikost signálu,  $A$  je původní nezašuměný obrázek,  $n_1$  a  $n_2$  nekorelovatelné proměnné *Gaussova* šumu s nulovou střední hodnotou a stejným rozptylem  $\sigma_n^2$ .

Hustota pravděpodobnosti pro takový obraz je dána následujícím vzorcem: [17]

$$p(x) = \frac{x}{\sigma^2} \exp\left(-\frac{x^2 + A^2}{2\sigma^2}\right) I_0\left(\frac{xA}{\sigma^2}\right) \quad (5)$$

Kde  $A$  je skutečná intenzita,  $\sigma$  je standardní odchylka šumu a  $I_0$  je modifikovaný nulový řád *Besselovy* funkce prvního druhu. [17, 18]

### 3.1.6 Ostatní typy šumů

Výše uvedené typy šumů patří mezi nejčastější, proto je každý uveden v samostatné podkapitole. Tato podkapitola uvádí pouze názvy některých ostatních typů šumů, mezi které patří kvantizační šum, fotonový šum, brownův šum, periodický šum apod. [12, 13]


## 3.2 Filtrace obrazu na základě 2D konvoluce

Filtrace je používána v rámci předzpracování obrazu, kdy dojde k úpravě dat obrazu. Používají se k odstranění šumů apod. Jejich základní rozdělení je na nízkofrekvenční a vysokofrekvenční filtry.

Na začátku této podkapitoly je také popisovaná konvoluce z obecného hlediska, jelikož se jedná o stěžejní věc každého filtru a není stejná pro každý jednotlivý filtr.

Konvoluce je matematická operace využívající konvoluční matici, nazývané „jádro“. Používá se k odstranění šumu v obrazech, zvukových přenosech apod. V našem případě bude konvoluce vysvětlena v rámci filtrace obrazu. Obraz je v podstatě matice pixelů (s určitým počtem řádků a sloupců), kdy každý pixel má číselnou hodnotu. Filtr pomocí konvoluční matice zpracuje každý jednotlivý pixel obrázku. Základní velikost konvoluční matice je  $3 \times 3$ , kdy se velikost volí podle požadovaného účinku. Je ale nutné zmínit, že čím větší rozměry konvoluční matice, tím větší výpočetní náročnost. Při samotné aplikaci filtru se jako první matice použije zpracovávaný obrázek, na který je aplikována konvoluční matice (tím je vymezena právě zpracovávaná oblast). Po aplikaci konvoluční matice s daným rozměrem každá jednotlivá buňka konvoluční matice zpracuje příslušný pixel (většinou násobením, v případě Mediánového filtru

vzestupné seřazení pixelů ve vymezené oblasti) zpracovávaného obrázku. Poté se ze všech právě vypočítaných hodnot vypočítá jedna nová hodnota. Novou hodnotou je nahrazen středový pixel ze zpracovávaného obrázku. Poté se konvoluční matice posune o buňku dále a zpracuje další středový pixel zpracovávaného obrázku. Takto pokračuje do té doby, než je zpracován celý obrázek. V případě krajních pixelů se použije tzv. zero padding, kdy se nulami doplní obrázek tak, aby středy mohly být také krajní pixely. Na obrázku 10 lze vidět příklad konvoluce. [19, 20, 21, 22]



Obrázek 10: Příklad konvoluce [19]

### 3.2.1 Nízkofrekvenční filtry

Nízkofrekvenční filtry (*angl. Low frequency filters*) slouží, jak již název napovídá, k odstranění vysokých frekvencí (obraz tzv. vyhlazuje), zatímco nízké frekvence jsou puštěny. Mezi základní nízkofrekvenční filtry patří Obyčejné průměrování, Gaussův filtr a Mediánový filtr. [23]

#### 3.2.1.1 Průměrový filtr

Průměrový filtr (*angl. Square Mean, Circle Mean*) má takový princip, že každý jednotlivý pixel původního obrazu (samotný obraz je také matice, přičemž každý pixel má číselnou hodnotu) substituuje průměrnou hodnotou jeho 8-okolí a jeho samotného – tento proces je nazýván konvoluce. K tomu se hlavně využívá konvoluční matice 3×3, která je níže uvedena; vlevo je matice pro *Circle Mean* filtr a vpravo pro *Square Mean* filtr: [23]

$$\begin{pmatrix} 1/9 & 1/9 & 1/9 \\ 1/9 & 1/9 & 1/9 \\ 1/9 & 1/9 & 1/9 \end{pmatrix} \begin{pmatrix} 0 & 1/5 & 0 \\ 1/5 & 1/5 & 1/9 \\ 0 & 1/5 & 0 \end{pmatrix} \quad (6)$$

Lze použít konvoluční matice o větších rozměrech. Při aplikaci filtru s menší konvoluční maticí několikrát za sebou získáme výsledek, který je obdobný výsledku po použití filtru s větší maticí. *Circle Mean* filtr má ve výsledku jemnější vyhlazení oproti *Square Mean* filtru. [23]

### 3.2.1.2 Gaussův filtr

Patří mezi nejúčinnější a je rozšířením *Obyčejného průměrování*, tak vzniká průměrování s Gaussovským rozložením, respektive Gaussův filtr. Je používán k eliminaci detailů, šumu a k vyhlazování obrazu, kdy má lepší výsledky při odstraňování šumu pro větší masky. Při použití větších masek však dochází k většímu rozmazávání obrazu, a to je také jeho hlavní nevýhodou, jelikož to může být problematické při následné detekci hran. Jeho aplikaci lze provést třemi způsoby, a to konvolucí, Fourierovou transformací a rekursivními filtry.

Konvoluční matice může mít následující tvar: [23]

$$\frac{1}{16} * \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix} \quad (7)$$


Můžeme si všimnout, že po vynásobení vahou součtu všech položek matice získáme výsledek 1, což zajistí, že nedojde ke změně celkové světlosti obrázku. Je ale nutno matici upravit, a to zvýšením váhy středového bodu konvoluční masky nebo také jeho 4-okolí, v opačném případě by rozměr masky byl nekonečný. Matice má většinou rozměr  $3 \times 3$  a zpracovává každý jednotlivý pixel obrazu. Má takový princip, že každý jednotlivý pixel zpracovávaného obrazu substituuje hodnotu, která je rovna součtu vynásobení aktuálního pixelu (zpracovávaného pixelu) a jeho osmi sousedních pixelů, konvoluční maticí s odpovídajícími hodnotami masky. Čím větší je konvoluční matice, tím větší je časová náročnost operace. Jednou z možností, jak urychlit výpočet této operace u větších matic, je použití Fourierovy transformace.

Fourierova transformace vychází z toho, že místo konvoluce lze použít násobení, jelikož výpočetní náročnost je téměř totožná jak pro malá, tak pro velká konvoluční jádra. Časová náročnost operace se proto nezvyšuje tolik jako v situaci konvoluce.

Další možností aplikace Gaussova filtru je užití rekursivních filtrů. Podstatou je, že konvoluce není přepočítávána pro každý jednotlivý pixel, ale k počítání hodnoty nějakého bodu je využito již předtím počítaných hodnot z předcházejících bodů. Princip ale není tak jednoduchý, jak se na první pohled zdá. Jelikož při posunutí konvolučního jádra nastává posun jeho koeficientů, sčítance nesedí jako u konvoluce. Z toho jasně vyplývá, že námět rekursivního filtru je složitá věc. [21, 23]

### 3.2.1.3 Mediánový filtr

Vyhlazuje lokální extrém, proto se používá k eliminaci šumu *Šůl a pepř*, a k tomu využívá medián. Jako první vzestupně nebo sestupně seřadí hodnoty konvoluční matice, a následně vybere hodnotu ležící uprostřed (onen medián). V případě sudého počtu prvků je medián spočten jako průměr dvou prostředních prvků. Novou hodnotou (mediánem/průměrem) je poté nahrazen právě zpracovávaný bod. V určitých případech může být výhodnější použít konvoluční matici o větších rozměrech než  $3 \times 3$ . Je tu však riziko v podobě většího rozmazání obrazu a ztráty detailu. Nejčastější velikosti konvoluční matice jsou  $3 \times 3$ ,  $4 \times 4$  a  $5 \times 5$ . Je nutné podotknout, že k eliminaci šumu *Šůl a pepř* se hodí lépe než *Průměrový filtr*. Obrázek 11 ilustruje princip filtru. [21, 23]



**Obrázek 11:** Vlevo zobrazení konvoluční matice o rozměrech 3×3, následné zjištění mediánu a nahrazení původní hodnoty novou [23]

### 3.2.2 Vysokofrekvenční filtry

Místa s náhlou změnou jasu se nazývají hrany a jsou neméně důležité v obraze. K jejich detekci v obraze se používají vysokofrekvenční filtry. Výstupem těchto filtrů je obraz se zvýrazněnými hranami, jenž ale může obsahovat ostatní artefakty.

Hrany jsou stanoveny náhlou změnou hodnoty obrazové funkce parciální derivace  $f(x, y)$ . Změna je stanovena *gradientem* – vektor udávající prudkost růstu (velikost neboli modul gradientu) a směr největšího růstu funkce (směr gradientu). Pixely mající velký modul gradientu jsou identifikovány jako hrany. [23, 24]

#### 3.2.2.1 Laplaceův filtr

Tento filtr se stará jen o velikost gradientu nehledě na jeho směr. K zjištění velikosti využívá *Laplaceův operátor* (resp. *Laplacián*) vycházející z druhých parciálních derivací, které jsou uvedené v následujícím vzorci: [23]

$$\nabla^2 g(x, y) = \frac{\delta^2 g(x, y)}{\delta x^2} + \frac{\delta^2 g(x, y)}{\delta y^2} \quad (8)$$

Kde  $g(x, y)$  jsou souřadnice pixelu v horizontálním a vertikálním směru,  $\delta$  je parciální derivace a  $\nabla$  znamená *Laplaceův operátor*.

*Laplaceův operátor* je při zpracování digitálního obrazu taktéž aproximován diskrétní konvolucí. Používané konvoluční matice o rozměru 3×3 (pro 4-okolí a 8-okolí) mají následující tvar: [25]

$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad (9)$$

První konvoluční matice je pro *pozitivní Laplacián*, druhá je pro *negativní Laplacián*. [23, 25]

#### 3.2.2.2 Sobelův filtr

Patří mezi směrově závislé filtry (resp. operátory), kdy směr je určován podle světových stran. Užitím tohoto filtru dochází k aproximaci první parciální derivace 2D funkce, kterou zastupuje zpracovávaný obraz. Konvoluční masky mají velikost 3×3 a jsou využívány pro všech osm směrů (*sever*, *východ* apod.). Níže

jsou konvoluční masky pro *sever* a *severovýchod* [23]. Další lze jednoduše získat pootočením v požadovaném směru.

$$\begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix} \begin{pmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{pmatrix} \quad (10)$$

Podle následujících vzorců lze zjistit hranu  $d$  a směr hrany  $s$ : [25]

$$d = \sqrt{x^2 + y^2} \text{ nebo } d = |x| + |y| \quad (11)$$

$$s = \arctg\left(\frac{y}{x}\right) \quad (12)$$

Kdy  $x$  a  $y$  představuje souřadnice pixelu v horizontálním a vertikálním směru. [23, 26]

### 3.2.2.3 Prewittův, Kirschův a Robinsonův filtr

Tyto filtry využívají stejný princip jako Sobelův filtr. Liší se pouze v podobě konvoluční masky, kdy příklad pro *severní* směr je uveden v následujícím vzorci pro *Prewittův* [27], *Kirschův* (*východní* směr) [28] a *Robinsonův* filtr [29].

$$\begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix} \begin{pmatrix} -3 & -3 & -3 \\ -3 & 0 & -3 \\ 5 & 5 & 5 \end{pmatrix} \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad (13)$$

Další si lze vytvořit stejně jako v případě *Sobelova* filtru. [23, 27, 28, 29]

## 3.3 Hodnotící parametry kvality obrazu

Existují objektivní metody hodnocení, sloužící k zjištění kvality obrazu po filtraci, kdy obrazy před a po filtraci jsou porovnávány mezi sebou. Výstupem těchto metod jsou parametry, na jejichž základě lze určit kvalitu filtrace z pohledu úbytku užitečné informace a utlumení rušivého šumu. [30]

### 3.3.1 SNR neboli odstup signálu od šumu

Parametr *SNR* (*z angl. Signal to Noise Ratio*) je často používanou metodou hodnocení. Udává, jaký je poměr výkonu užitečného a výkonu neužitečného signálu (šum). Kvalitu určuje výsledná hodnota *SNR*, přičemž čím vyšší je hodnota *SNR*, tím méně šumu se nachází v obraze oproti užitečnému signálu. Takhle lze určit efektivnost filtrace a přesnost odhadu šumu.

$$SNR_{dB} = 10 \log_{10} \frac{\sum_n s^2(n)}{\sum_n (s(n) - \hat{s}(n))^2} \quad (14)$$

Výše uvedená rovnice [30] slouží k výpočtu  $SNR$ , kdy  $s(n)$  znamená obraz po filtraci,  $\hat{s}(n)$  obraz před filtrací a jednotkou je *decibel dB*. [30]

### 3.3.2 MSE neboli střední kvadratická chyba a PSNR neboli špičkový odstup signálu od šumu

Parametr  $MSE$  (z angl. *Mean Squared Error*) je nejjednodušší metoda hodnocení kvality, kdy se zjišťuje střední kvadratická chyba mezi původním a zašuměným obrázkem.

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - Y_{i,j})^2 \quad (15)$$

Výše uvedená rovnice [30] slouží k výpočtu  $MSE$ , přičemž výpočet nezávisí na umístění pixelů v okně.  $M$  znamená velikost obrazu na ose  $x$ ,  $N$  znamená totéž, jen na ose  $y$ .  $X_{i,j}$  představuje pixel z obrazu po filtraci na souřadnicích  $i, j$ , a  $Y_{i,j}$  představuje pixel z obrázku na souřadnicích  $i, j$  z původního zašuměného obrázku.

Parametr  $PSNR$  (z angl. *Peak Signal to Noise Ratio*) udává poměr mezi maximálně možným výkonem užitečného a neužitečného signálu (šum), přičemž vychází z  $MSE$ . Výpočet je dle následujícího vzorce: [31]

$$PSNR_{dB} = 10 \log_{10} \left( \frac{m^2}{MSE} \right) \quad (16)$$

Kde  $m$  udává, jaké maximální hodnoty může pixel v obrázku nabývat, například 255 v případě 8-bitového obrázku. Jednotkou je *decibel dB*. Je-li obraz po filtraci kvalitní, měla by jeho hodnota  $PSNR$  dosahovat hodnoty okolo 50 *dB*. [30, 31, 32, 33, 34]

### 3.3.3 Q-index neboli univerzální index kvality

$Q$ -index (z angl. *A Universal Image Quality Index*) hodnotí několik parametrů. Prvně zhodnotí stupeň lineární korelace mezi zašuměným obrazem a obrazem po filtraci. Jeho hodnota je v rozmezí -1 až 1. Je-li hodnota 1, jsou obrazy totožné (tudíž filtrace nebyla účinná).

Dále je zhodnocena podobnost průměrného jasu mezi zašuměným obrazem a obrazem po filtraci. Jeho hodnota je v rozmezí 0 až 1. Je-li hodnota 1, jsou obrazy opět totožné.

Posledním zhodnoceným parametrem je podobnost kontrastů v obrazech. Hodnoty jsou v rozmezí 0 až 1.

Výše uvedené tři parametry jsou vypočítané v jedné rovnici. Konečná hodnota  $Q$ -indexu je v rozmezí -1 až 1. Výpočet  $Q$ -indexu je ve srovnání se  $SNR$  a  $PSNR$  náročnější. Tento parametr je vypočítán postupně



v celém obraze, a to tak, že je vypočítáván v dílčích krocích o délku strany masky pomocí následující rovnice: [30]

$$Q = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \frac{2\bar{x}\bar{y}}{(\bar{x})^2 + (\bar{y})^2} \frac{2\sigma_x \sigma_y}{2\sigma_x^2 - \sigma_y^2} \quad (17)$$

Kde  $\sigma_{xy}$  je směrodatná odchylka mezi obrazem  $x$  (zašuměným) a  $y$  (po filtraci),  $\sigma_x \sigma_y$  jsou dílčí směrodatné odchylky obrazu  $x$  a  $y$ , kdy ve všech krocích pohybující se masky jsou vypočítány tyto směrodatné odchylky. Proměnné  $\bar{x}\bar{y}$  představují průměrné hodnoty pixelů v masce, v níž je  $Q$ -index vypočítáván. Poté, co jsou vypočítány dílčí kroky užitím masky a taktéž dílčí  $Q$  parametry, je vypočítán průměr z těchto parametrů, který je reprezentativní hodnotou  $Q$ -indexu. [30]

### 3.3.4 SSIM neboli strukturální index podobnosti

SSIM (*angl. Structural Similarity Index*) je parametr používaný k měření kvality poškozeného obrázku. Porovnává poškozený obrázek (zašuměný) vůči referenčnímu obrázku (resp. dvou obrazových signálů) a funguje na základě tří složek (kontrastní podobnost, jasová podobnost a podobnost strukturální). Navíc je navržen tak, že bere v potaz vizuální systém člověka. Výsledná hodnota se pohybuje v rozmezí od 0 do 1, kdy 1 vyjadřuje, že oba porovnávané obrázky jsou totožné. Čím více se ale hodnota blíží k 0, tím jsou obrázky rozdílnější.

Vzorec používaný k výpočtu SSIM pro obrazové signály  $x$  a  $y$  je následující: [32]

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (18)$$

Kde  $l(x, y)$  je srovnávání podobnosti jasu signálů,  $c(x, y)$  je srovnávání kontrastu signálů, a  $s(x, y)$  je měření strukturální podobnosti signálů.

Výše uvedené veličiny se vypočítají podle následujících vztahů: [33]

$$l(x, y) = \frac{2\mu_x \mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (19)$$

$$c(x, y) = \frac{2\sigma_x \sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (20)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3} \quad (21)$$

Kde  $\mu_x$  a  $\mu_y$  jsou středními hodnotami vzorků signálů  $x$  a  $y$ ,  $\sigma_x$  a  $\sigma_y$  jsou rozptyly ze vzorků signálů  $x$  a  $y$ ,  $\sigma_{xy}$  znamená vzájemnou kovarianci mezi signály  $x$  a  $y$ . Vzorce k jejich výpočtům jsou uvedeny níže: [32]

$$\mu_x = \frac{1}{N} \sum_{i=1}^N x_i \quad (22)$$

$$\mu_y = \frac{1}{N} \sum_{i=1}^N y_i$$

$$\sigma_x = \left( \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_x)^2 \right)^{\frac{1}{2}} \quad (23)$$

$$\sigma_y = \left( \frac{1}{N-1} \sum_{i=1}^N (y_i - \mu_y)^2 \right)^{\frac{1}{2}}$$

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y) \quad (24)$$

$C_1$ ,  $C_2$  a  $C_3$  konstanty jsou používány za účelem stabilizace, kdyby rozptyl a průměr byly velmi malé hodnoty. Charakteristické veličiny  $\alpha > 0$ ,  $\beta > 0$  a  $\gamma > 0$  jsou užívány pro nastavení relativní důležitosti ze tří složek. Tyto veličiny ale z důvodu zjednodušení *SSIM* mají následující nastavení:  $\alpha = \beta = \gamma$  a  $C_3 = C_2/2$ .

Rovnici 21 lze tudíž celkově zjednodušit na následující rovnici: [32]

$$SSIM(x, y) = \left( \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right) \cdot \left( \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right) \quad (25)$$

Na závěr ještě nutno podotknout způsob výpočtu konstant  $C_1$  a  $C_2$ , který je uveden níže: [33]

$$C_1 = (K_1 L)^2 C_2 = (K_2 L)^2 \quad (26)$$

Kde  $L$  zastupuje dynamický rozsah obrazových bodů (pro 8bitové obrázky 0 až 255 bodů),  $K_1$  a  $K_2$  představují malé kladné konstanty.

Hodnota *SSIM* je počítána pro každý jednotlivý bod obrazu ( $i, j$ ), kdy výsledná hodnota udávající kvalitu obrazu se počítá užitím středního *SSIM* indexu: [33]

$$MSSIM = \frac{1}{M} \sum_i \sum_j SSIM(i, j) \quad (27)$$

Kde  $M$  znamená výsledné kvantum lokálních  $SSIM$  indexů.

[32, 33, 34]

## 4 Analýza Non-Local Means pro filtraci MR obrazových dat


V této kapitole je na začátku uvedena tabulka s informacemi o vybraných obrazových data setech, na kterých byla testována Non-Local Means filtrace. Následně je zaměřena na samotnou filtrační metodu, kde je podrobně rozebrán její princip. Na tuto část navazuje popis jednotlivých funkcí, které byly vytvořeny pro SW (z angl. *Software, Software*) prostředí GUI (z angl. *Graphical User Interface, Grafické uživatelské rozhraní*) aplikace za účelem implementace Non-Local Means filtrace a poté je popis ovládání samotného GUI aplikace.

### 4.1 Popis vybraných obrázků

V níže uvedené tabulce 1 jsou obsaženy informace o vybraných obrazových data setech. Nutno podotknout, že data byla stažena z webu *The Cancer Imaging Archive*, na kterém jsou veřejně dostupné diagnostické snímky různých oblastí lidského těla postižených rakovinou. Ovšem data z oblasti kolenní chrupavky mi byla poskytnuta vedoucím diplomové práce. Na obrázcích 12, 13, 14, 15 a 16 lze vidět ukázkou z jednotlivých oblastí.

**Tabulka 1:** Informace o vybraných obrazových data setech [vedoucí diplomové práce, 35, 36, 37, 38]


Datová sada	Kolenní chrupavka	Děloha	Mozek	Prostata	Ženská prsa
Počet obrázků	15	15	15	15	15
Rozlišení	512×512	512×512	512×512	256×256	288×288
Formát	.png	.jpg	.jpg	.jpg	.jpg



**Obrázek 12:** Ukázka obrázků z oblasti kolenní chrupavky. Zdroj vedoucí diplomové práce.




**Obrázek 13:** Ukázka obrázků z oblasti dělohy [35]



**Obrázek 14:** Ukázka obrázků z oblasti mozku [36]



**Obrázek 15:** Ukázka obrázků z oblasti prostaty [37]



**Obrázek 16:** Ukázka obrázků z oblasti ženských prsou [38]


## 4.2 Filtrační metoda Non-Local Means

Snímky z MR jsou při vzniku poškozeny náhodným šumem, který snižuje přesnost kvantitativního měření z dat. Nicméně úroveň šumu lze snížit zvýšením průměru akvizice přímo v přístroji. Toto ale není běžnou praxí, jelikož dochází ke zvyšování časové náročnosti. Proto byl navržen tento filtr, kdy obrázky z MR vyšetření projdou filtrací touto metodou. [39, 40]

### 4.2.1 Princip

Princip Non-Local Means filtru (NLM) je založen na podobnosti pixelů. V celém obraze jsou oblasti, resp. struktury, jejichž obrazové charakteristiky vykazují vysokou míru podobnosti, kdy oblasti s výskytem hran a detailů jsou považovány za vysokou frekvenci v obraze.

*NLM* filtr hledá podobnosti mezi zpracovávaným pixelem (resp. pixel, který má být filtrován) a postupně všemi pixely v obrázku. Uvedme si příklad, kdy označíme zpracovávaný pixel jako  $p$  s definovaným okolím (resp. sousedstvím) (většinou  $3 \times 3$ ), poté  $q1$  a  $q2$  jsou pixely, které jsou porovnávány s  $p$  a také mají definované okolí (resp. sousedství) o stejné velikosti jako pixel  $p$ . Obrázek 17 znázorňuje právě popsané konkrétní porovnávání.



**Obrázek 17:** Porovnávání podobnosti mezi pixelem  $p$  vůči  $q1$  a  $q2$ . Zdroj vedoucí diplomové práce, přičemž obrázek byl upraven.

Pixel  $p$  je podobnější  $q1$ , protože oblast, kde leží  $q2$ , má zcela odlišný jas. Podobnost mezi pixely  $p$  a  $qn$  je vypočítaná jako *váha*  $w$  na stupnici 0 až 1. Je-li výsledek 0, znamená to, že porovnávané oblasti nejsou podobné, je-li výsledek 1, oblasti jsou stejné. *Váha*  $w$  je vypočítána podle následujícího vztahu: [43]

$$w(p,q) = e^{-\frac{|B(q)-B(p)|^2}{\sigma^2}} \quad (27)$$

Kde  $|B(q) - B(p)|^2$  představuje rozdíl střední hodnoty mezi okolím zpracovávaného pixelu a okolím pixelu zrovna porovnávaného. Kdy  $\sigma^2$  je *Gaussovský rozptyl* okolí (resp. sousedství) zpracovávaného a porovnávaného pixelu, přičemž se jedná o parametr, kterým je nastavena síla filtrace.

Střední hodnota je určena následujícím vztahem: [43]

$$B(p) = \frac{1}{|R(p)|} \sum_{i \in R(p)} v(i) \quad (28)$$

Kde  $R(p)$  je počet pixelů okolí (resp. sousedství) a  $v(i)$  jsou hodnoty pixelů okolí (resp. sousedství). V případě výpočtu pro pixel, který je porovnáván vůči zpracovávanému pixelu (zde ve vzorci označení pro zpracovávaný pixel  $p$ ), se pouze zamění označení  $R(p)$  za  $R(q)$  a  $B(p)$  za  $B(q)$ .

Tímto způsobem se spočítají všechny *váhy*  $w$  v obrázku (ovšem oblast, ze které se budou vybírat pixely k porovnávání vůči zpracovávanému pixelu může být omezena, tudíž se nemusí jednat o celý obrázek) vůči

zpracovávanému pixelu. Poté, jedná-li se o obrázek, který se mění spojitě v čase, nová hodnota pro zpracovávaný pixel  $p$  na souřadnicích  $i$  a  $j$  se vypočítá dle následujícího vzorce: [43]

$$p(i,j) = \frac{1}{C(p)} \int_{\Omega} v(q) w(p, q) dq \quad (29)$$

Kde  $v(q)$  znamená hodnota porovnávaného pixelu při výpočtu vlastní váhy  $w$ ,  $\Omega$  znamená oblast obrázku nebo vymezené oblasti, ze které se vybírají pixely k porovnání.  $C(p)$  je normalizační faktor, který se vypočítá dle následujícího vzorce: [43]

$$C(p) = \int_{\Omega} w(p, q) dq \quad (30)$$

Ovšem jedná-li se o diskrétní obrázek, nová hodnota pro zpracovávaný pixel  $p$  se vypočítá dle následujícího vzorce: [43]

$$p(i,j) = \frac{1}{C(p)} \sum_{q \in \Omega} v(q) w(p, q) dq \quad (31)$$

Lze si povšimnout, že tento vzorec je velmi podobný vzorci 29, kdy jediný rozdíl je, že místo  $\int$  se použije  $\sum$ . Totéž platí pro výpočet normalizačního faktoru: [43]

$$C(p) = \sum_{q \in \Omega} w(p, q) \quad (32)$$

Sama filtrace je také závislá na velikosti porovnávané oblasti  $n$  (resp. oblasti, ze které jsou vybírané pixely k porovnávání vůči zpracovávanému pixelu) a okolí  $f$  (resp. sousedství). Je-li hodnota  $n$  nízká, například 3, porovnávací oblast bude dána maticí  $3 \times 3$  (dána 9 pixely, je-li  $n = 3$ ), přičemž bude vybráno  $qn - 1$  pixelů k porovnávání. Čím větší hodnota  $n$ , tím větší časová náročnost, a hodnota  $f$  ovlivňuje okolí (resp. sousedství) pixelu  $p$  a  $qn$ . Vysoká hodnota  $f$  může zapříčinit podobnost mnoha oblastí nebo jejich vysokou váhu, což v důsledku způsobí větší rozmazání obrazu. [41, 42, 43]

### 4.3 Softwarové prostředí pro testování Non-Local Means

V této podkapitole jsou řešeny funkce, které byly vytvořeny pro SW prostředí GUI aplikace, kde lze implementovat NLM filtr. Do aplikace lze nahrát MR obrazová data, na které budou aplikovány vybrané šумы s vybranými hodnotami šumových parametrů, na které lze následně aplikovat NLM filtr se zvolenou silou filtrace  $\sigma^2$ . Mezi jednotlivými obrázky lze simultánně přepínat a samozřejmostí je zobrazování výsledků evaluačních parametrů určující kvalitu filtrace u každého filtrovaného obrázku, kdy tyto výsledky je možno uložit. Uložit také lze samotné zašuměné a filtrované obrázky, také soubor se shrnujícími informacemi ohledně názvu vybraných obrázků, jejich adresáře, zvolených šumů a šumových parametrů.



### 4.3.1 Popis softwarové části

Pro tuto aplikaci byly vytvořeny následující funkce: hlavní funkce *NLM\_filter.m* a *NLM\_filter.fig*, *evaluate\_data.m*, *evaluation.m*, *filter\_process.m*, *save\_data.m*, *view\_picture.m* a *view\_picture\_for\_addednoise\_filter.m*.

#### 4.3.1.1 Funkce *NLM\_filter.m* a *NLM\_filter.fig*

Níže jsou popsány funkce, které jsou uloženy v souboru *NLM\_filter.m*, přičemž vzhled GUI je uložen v *NLM\_filter.fig*.

**Funkce pro výběr a načtení obrázků:** Slouží pro výběr jednoho či více obrázků do aplikace, na obrázku 14 lze vidět její výstup a spouští se kliknutím na tlačítko *Load data* v GUI. Po spuštění se nejprve definuje proměnná *str*, která dává možnost samostatného výběru obrázků nebo složky s obrázky. Následně se definuje proměnná *s*, ve které jsou v momentě výběru uložené vybrané obrázky. Také se definuje proměnná *filename* a *path* pro ukládání jména a adresáře vybraných obrázků. Na konci dojde k zobrazení prvního obrázku do *axes1*, což je okno, kde se zobrazují vybrané obrázky.

**Funkce pro zobrazení adresáře obrázků a uložení do souboru *handles.m*:** Do proměnné *filename* se uloží jméno obrázků a *path*, což je jejich adresář. Následně se informace z této proměnné zobrazí v *edit1*, což je místo v GUI, kde je zobrazován adresář obrázků. Poté se v souboru *handles.m* uloží samotné obrázky pod proměnou *Original Data*, která je vnořena do proměnné *Images*.

**Funkce pro přepínání mezi obrázky:** Nejprve zjistí, zda za nebo před zobrazovaným obrázkem je další, a to nahlédnutím do *handles.m*, kde v proměnné *Original Data* zjistí počet řádků, kdy každý řádek představuje jeden obrázek. Existuje-li více řádků, dojde k jeho přečtení a následnému zobrazení v *axes1*, přičemž k přepínání jsou používány šipky pod zobrazovanými obrázky. Nutno ovšem podotknout, že v tomto souboru se odvolává na *view\_picture.m* funkci, kde probíhají hlavní procesy umožňující přepínání mezi obrázky, a níže je vysvětlena její funkcionalita.

**Funkce pro přečtení vybraných šumů, jejich zadaných šumových parametrů a zašumění obrázků:** Tato funkce si načte *handles.m*, kde nejprve zjistí velikost obrázků a poté zjišťuje vybrané šumy, a to tak, že zkontroluje *checkbox1* až *checkbox5*, což jsou políčka pro výběr požadovaných šumů. Poté, byl-li šum vybrán, přečte jednotlivé vybrané hodnoty šumových parametrů, které jsou uloženy v proměnné *parameters*. Následně kliknutím na tlačítko *Add noise* dojde k zašumění obrázků a jejich zobrazení v *axes2*, což je okno pro zobrazování zašuměných obrázků, a zobrazení je provedeno pomocí *view\_picture\_for\_addnoise\_filter.m* funkce, kde probíhají hlavní procesy pro zobrazení a jejíž funkcionalita je vysvětlena níže. Také dojde k vytvoření proměnných v *handles.m* pojmenovaných podle jmen vybraných šumů.

**Funkce pro uložení přehledového .txt souboru:** Slouží pro ukládání základních dat o vybraných obrázcích do *log\_file.txt* souboru. Nejprve se vytvoří proměnná *file ID*, do které je uložen adresář a jméno vybraných obrázků, poté hodnoty šumových parametrů vybraných šumů, hodnota filtračního parametru

a případně ještě hodnota *imageresize*, což je vestavěná funkce pro zmenšování obrázků. Poté vytvoří *log\_file.txt* soubor v místě umístění aplikace, kde budou všechna tato data uložena. Příklad je uveden na obrázku 25.

**Funkce pro spuštění filtrace:** Přečte zadanou hodnotu filtračního parametru a uloží ji do proměnné *f*, která je následně přečtena Non-local Means filtrem (tato funkce se na daný filtr odkazuje na funkci *filter\_process.m*) po spuštění filtrace kliknutím na tlačítko *Filter data*. Po dokončení filtrace se vytvoří *filtered\_Images.m* soubor, kde je proměnná *P* a v ní jsou jednotlivé proměnné, které jsou pojmenovány podle vybraných šumů na začátku, kdy každá proměnná má opět maticovou strukturu.

**Funkce pro ukládání zašuměných a filtrovaných obrázků:** Spustí se kliknutím na tlačítko *Save data*, z *handles.m* vybere zašuměné obrázky a z *filtered\_Images.m* vybere filtrované obrázky a uloží je v místě, které si zvolí uživatel. Je nutné ale říct, že v souboru *NLM\_filter.m* se odvolává na funkci *save\_data.m*, kde probíhají hlavní procesy, a níže je vysvětlena její funkcionalita.

**Funkce pro uložení výsledných hodnot určující kvalitu filtrace:** Spouští se kliknutím na tlačítko *Save evaluation data* v GUI, kdy v místě adresáře aplikace vytvoří *Average\_evaluation\_data.m* soubor, kde jsou tyto hodnoty uloženy v jednotlivých podsložkách, které jsou pojmenovány podle vybraných šumů na začátku procesu.

#### 4.3.1.2 Funkce *evaluation.m* a *evaluate\_data.m*

Funkce *evaluation.m* slouží pro výpočet hodnot hodnotících parametrů a jejich zobrazení v GUI. Nejprve si načte originální a filtrované obrázky. Poté je zjištěn šum, pod kterým se v GUI má ukázat zašuměný obrázek, a to tak, že zkontroluje *radiobutton1* až *radiobutton5*, což jsou políčka, kde si uživatel volí, pod jakým typem šumu si chce zobrazit zašuměný obrázek, také kontroluje, zda se daný obrázek nachází v *handles.m* souboru. Následně je převeden originální a filtrovaný obrázek na stejnou velikost pomocí funkce *size*. Po převedení na stejnou velikost jsou počítány hodnotící parametry, kdy výpočet probíhá mezi originálním a filtrovaným obrázkem.

Funkce *evaluation\_data.m* slouží k podobnému účelu jako výše zmíněná funkce, ale je upravená pro funkci *filter\_process.m*, kde touto funkcí jsou výsledky hodnotících parametrů ukládány do evaluační matice *evaluation\_matrix*.

#### 4.3.1.3 Funkce *filter\_process.m*

Slouží pro samotnou filtraci zašuměných obrázků. Nejprve je načtena proměnná *Images* ze souboru *handles.m*, zadaná hodnota filtračního parametru a proměnná *parameters*, kde jsou uloženy zadané hodnoty šumových parametrů. Poté nastává inicializace proměnných jako *filter\_Images*, *elapsed\_time* a *evaluation\_matrix*, kde budou uloženy hodnoty filtrovaných obrázků, čas filtrace a výsledky hodnotících parametrů po samotné filtraci. Také se inicializují proměnné hodnotících parametrů. Po inicializaci jsou vytvořeny databáze pro ukládání filtrovaných obrázků, času filtrace a hodnotících parametrů. Databáze budou mít maticovou strukturu zmíněnou výše, jejich velikost se odvíjí od počtu zašuměných obrázků

a jejich název odpovídá na začátku inicializovaným proměnným. Následně jsou zjištěny názvy vybraných šumů a parametry databáze, kde počet řádků představuje počet obrázků, počet sloupců představuje počet parametrů šumu. U Gaussovského šumu i počet stránek, které představují hodnotu šumového parametru rozptylu u tohoto šumu. Tím je uživateli umožněno zadat různé počty jakýchkoli šumových parametrů, to znamená, že počty parametrů u vybraných šumů se nemusí shodovat. V následném kroku je spuštěna samotná filtrace, kdy průběh filtrace je ukazován na samostatné liště a určování jejího výpočetního času. Po filtraci jsou výstupem filtrované obrázky, výpočetní čas filtrovaných obrázků a výsledky hodnotících parametrů, kde tyto hodnoty jsou uloženy v *handles.m* souboru.

#### 4.3.1.4 Funkce *save\_data.m*

Touto funkcí je zajišťováno ukládání zašuměných a filtrovaných obrázků kliknutím na tlačítko *Save data*. V prvním kroku je vytvořena složka pro zašuměné obrázky a vymazání originálních obrázků z databáze. Následně je vytvořena složka pro filtrované obrázky. Po tomto se v každé složce, jak pro zašuměné, tak pro filtrované obrázky, vytvoří podsložky, které jsou pojmenovány podle šumů, které byly na začátku procesu vybrány, a v nich budou dané obrázky uloženy. Po uložení obrázků dojde k ukončení této funkce.

#### 4.3.1.5 Funkce *view\_picture.m*

Tato funkce je zajišťuje přepínání mezi obrázky. V prvním kroku je zjištěno, zdali existují filtrované obrázky. Následně je zjišťován aktuální výběr šumů, a to kontrolou *radiobutton1* až *radiobutton5* (vysvětlení jejich funkce je v podkapitole 4.2.1.2). Po zjištění aktuálního výběru šumu zjišťuje, zda u daného vybraného šumu je před nebo za obrázkem další obrázek, pokud ano, dojde k přepnutí na další. V případě, že uživatel klikne v *radiobutton1* až *radiobutton5* na šum, který nebyl na začátku procesu vybrán, zobrazí se varovná hláška, příklad uveden na obrázku 22.

#### 4.3.1.6 Funkce *view\_picture\_for\_addednoise\_filter.m*

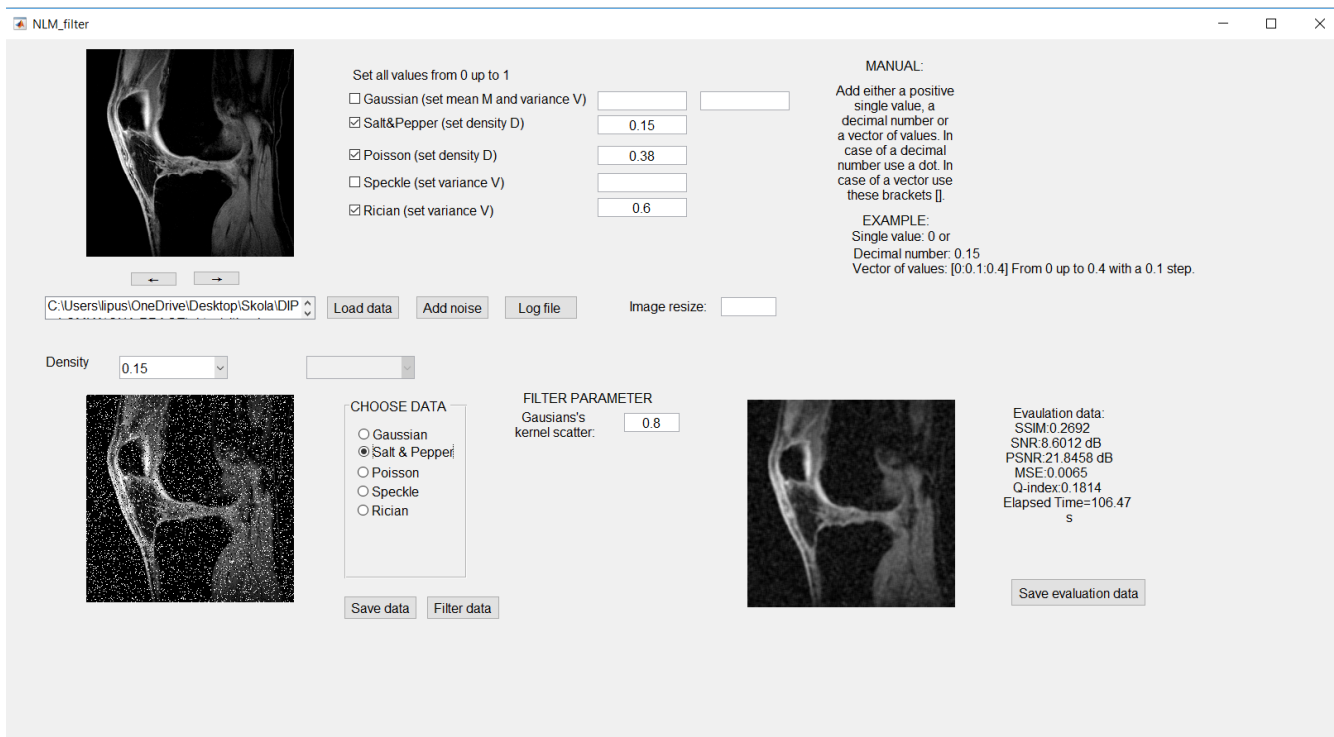
Touto funkcí je uživateli umožněno zobrazovat obrázky po jejich zašumění a filtraci v oknech pro zobrazování v GUI. V prvních dvou krocích je stejně jako u funkce *view\_picture.m* zjišťováno, zda existují filtrované obrázky a aktuální výběr šumů. Po tomto kroku je v *axes2* zobrazen zašuměný obrázek podle vybraného šumu a daný filtrovaný obrázek, byl-li filtrován v *axes3*, což je okno pro zobrazování filtrovaných obrázků.

### 4.3.2 Ovládání aplikace

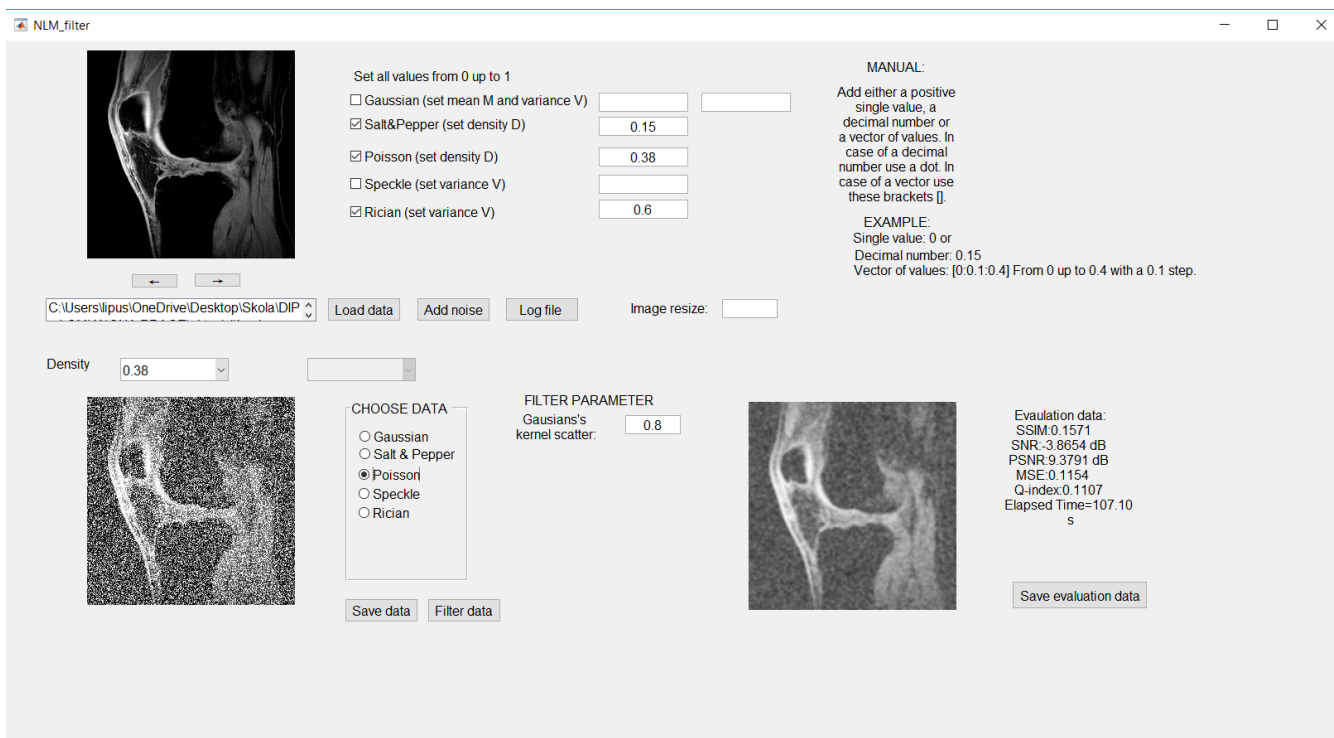
Aplikace je nazvána *NLM\_Filter* a její grafické uživatelské rozhraní lze vidět na obrázcích 18, 19 a 20. Je složena z 9 tlačítek, 2 rolovacích lišt, 5 checkboxů, 5 přepínačů, 8 zapisovacích oken, 3 zobrazovacích oken a 1 okna pro zobrazení adresáře načtených obrázků.

Chce-li uživatel načíst data, musí kliknout na tlačítko *Load data*, kdy následně se objeví dialogové okno s možnostmi *select a picture or pictures* a *select folder*. První volba dává možnost vybrat obrázky

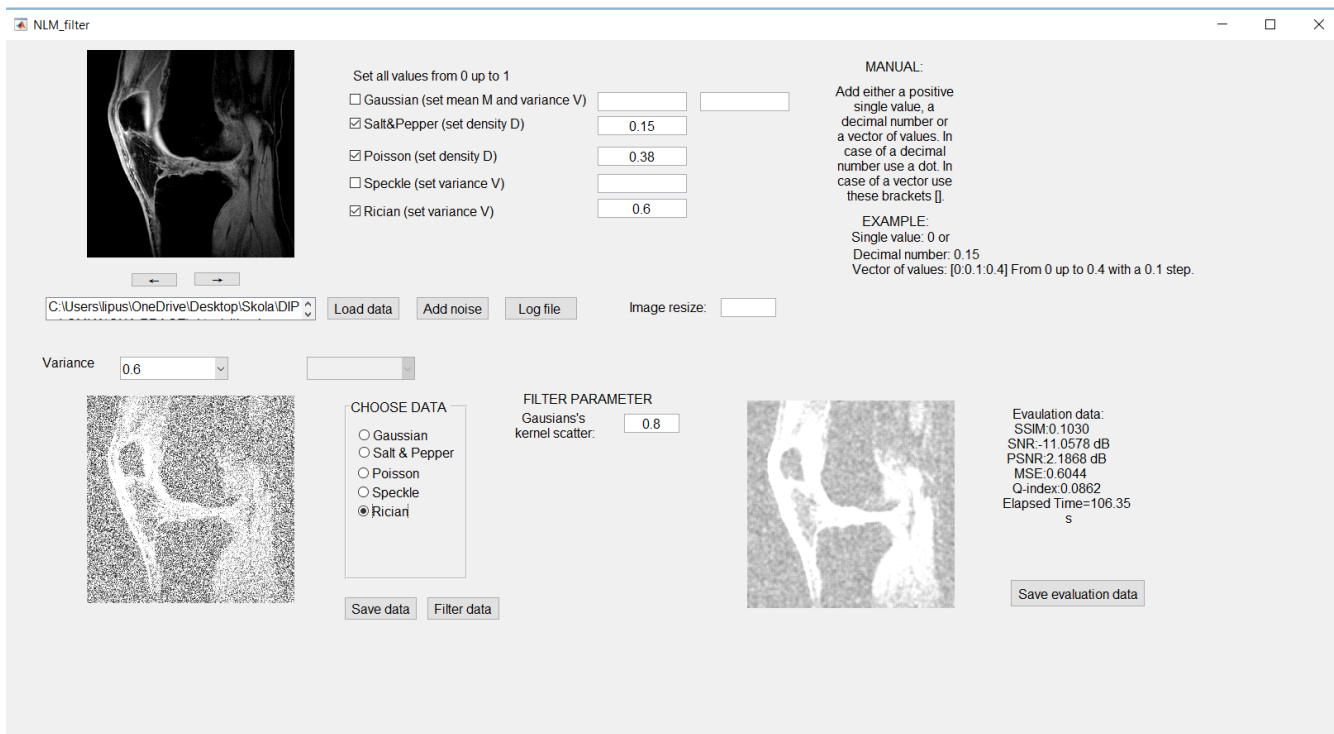
samostatně (ať už jeden či více obrázků) a druhá volba dává možnost vybrat složku s obrázky. Nutno podotknout, že obrázky musí být formátu *.jpg* nebo *.png*. Dialogové okno je na obrázku 21.




**Obrázek 18:** Grafické uživatelské rozhraní aplikace *NLM\_filter* s ukázkou filtrace pro Sůl&Pepř šum. Zdroj vlastní.



**Obrázek 19:** Grafické uživatelské rozhraní aplikace *NLM\_filter* s ukázkou filtrace pro Poisson šum. Zdroj vlastní




**Obrázek 20:** Grafické uživatelské rozhraní aplikace *NLM\_filter* s ukázkou filtrace pro šum Ricián. Zdroj vlastní



**Obrázek 21:** Dialogové okno. Zdroj vlastní.


Po kliknutí na jednu z voleb si uživatel vybere obrázky v místě uložení, kdy po načtení se první obrázek z vybraných zobrazí v horním levém zobrazovacím okně a mezi jednotlivými obrázky (v případě, že jich bylo vybráno více než 1) lze přepínat pomocí šipek pod tímto zobrazovacím oknem. Následně si uživatel kliknutím na vybraný checkbox zvolí, jakými šумы z 5 možností a pod jakými hodnotami šumových parametrů chce účelově poškodit vybraná data (hodnoty mohou být v rozsahu 0 až 1). Jedná-li se o jednu hodnotu šumového parametru, napíše se pouze číslo s tečkou jako oddělovačem desetinných míst, například 0.5, popřípadě se napíše 1 nebo 0 (0 v případě u jednoho z parametrů Gaussovského šumu, u ostatních by to nemělo smysl), nebo se napíše vektor hodnot v hranatých závorkách, například [0.1:0.1:0.3], kdy první číslo znamená první hodnota šumového parametru, druhé udává, s jakým krokem se má zvyšovat, a třetí, do jaké hodnoty se má zvyšovat. U Gaussovského šumu jsou šumové parametry střední hodnota  $M$  a rozptyl  $V$ , u šumu Sůl&Pepř a Poissonovského šumu to je hustota  $D$ , u Spekle a Riceovského šumu to je rozptyl  $V$ . Po tomto může ještě uživatel zmenšit vybrané obrázky, a to zapsáním hodnoty v rozmezí 0 až 1 do zapisovacího okna *Image resize*, například hodnotou 0.7 by došlo ke zmenšení obrázku o 70 % z původní velikosti. To se používá v případě, kdyby chtěl uživatel zkrátit výpočetní čas filtrace, jelikož čím menší obrázky, tím kratší výpočetní čas (ovšem zadání hodnoty 0 nebo 1 by bylo zcela nelogické). Po výběru uživatel klikne na tlačítko *Add noise*, kdy se vybrané obrázky poškodí vybranými šумы pod vybranými hodnotami šumových parametrů. Jakmile bude zašumění hotové, v zobrazovacím okně v levém dolním rohu se zobrazí zašuměný obrázek. Pomocí již výše zmíněných šipek lze opět přepínat mezi jednotlivými zašuměnými obrázky, kdy přepínání je simultánní, což znamená, že jaký obrázek půjde vidět v levém horním zobrazovacím okně, takový bude vidět v levém dolním zobrazovacím okně, jen zašuměný. Z oblasti *Choose data* si uživatel po kliknutí na daný přepínač zvolí, jaký typ šumu si chce prohlížet a po kliknutí na rolovací okno nad zobrazovacím oknem, kde jsou zobrazeny zašuměné obrázky, si vybere, pod jakou

hodnotou šumového parametru. Dvě rolovací okna tam jsou proto, jelikož u Gausovského šumu se určují dva šumové parametry, jak je již zmíněno výše. Stane-li se, že si uživatel vybere z oblasti *Choose data* šum, který na začátku nebyl vybrán, objeví se varovné okno, které uživatele upozorní, že daný šum neexistuje; zobrazeno na obrázku 22.



**Obrázek 22:** Varovné okno v případě výběru neexistujícího šumu. Zdroj vlastní.

Následně před spuštěním filtrace musí uživatel napsat hodnotu filtračního parametru  $\sigma^2$  do zapisovacího okna vedle zobrazovacího okna vpravo dole, u kterého je text *Gaussian's kernel scatter*, což znamená Gaussovské rozložení okolí (v podkapitole 3.3.1 je vysvětlení použitého filtru), a hodnota opět v rozmezí 0 až 1 (ovšem 0 by nedávala smysl). Jakmile je toto splněno, uživatel klikne na tlačítko *Filter data* pro započetí filtrace, kdy průběh filtrace ukazuje okno, jehož příklad je na obrázku 23.

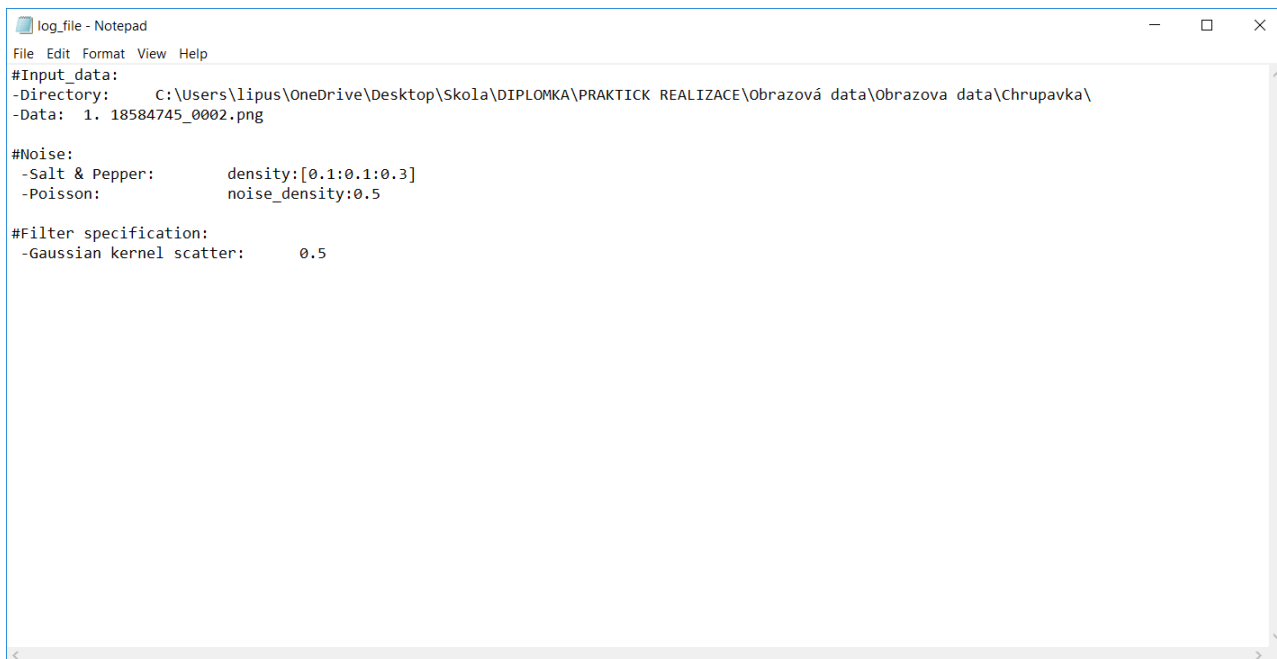


**Obrázek 23:** Okno ukazující průběh filtrace. Zdroj vlastní.

Jakmile je filtrace všech šumů dokončena, v zobrazovacím okně vpravo dole se zobrazí filtrovaný obrázek, vedle kterého jsou vypočítány evaluační parametry jako SSIM, SNR, PSNR, MSE a Q-index. Rovněž tam je zobrazen výpočetní čas filtrace. Opět pomocí šipek lze simultánně přepínat mezi jednotlivými obrázky, kdy v pravém dolním zobrazovacím okně bude filtrovaný obrázek, v levém horním bude tentýž, jen nepoškozený, a vlevo dole poškozený šumem.

Po dokončení filtrace si uživatel může uložit zašuměné a filtrované obrázky (zašuměné lze uložit již po zašumění originálních obrázků) kliknutím na tlačítko *Save data*, poté si vybere adresář uložení a na daném místě se vytvoří 2 složky s názvem *noisy\_images* a *filtered\_images*. V každé jsou další složky, které jsou pojmenovány podle vybraného šumu na začátku procesu, a v dané složce jsou dané obrázky, kdy ve složce *noisy\_images* jsou obrázky poškozené šumem a ve složce *filtered\_images* jsou filtrované obrázky. Obrázky jsou navíc pojmenovány podle názvu odkud byly načteny, šumového parametru a hodnoty šumového parametru, např. *MRI\_Density\_0\_5*, což znamená, že daný obrázek se jmenuje *MRI*, šumový parametr u daného šumu je hustota *D* a úroveň poškození daného obrázku šumovým parametrem *D* je 0,5. Pokud si chce uživatel uložit soubor se zvolenými hodnotami šumových parametrů vybraných šumů, s adresářem

vybraných obrázků, názvem obrázků, se zvolenou hodnotou  $\sigma^2$  a se zvolenou hodnotou zmenšení obrázků (resp. hodnotou *Image resize*, pokud byla zadaná), klikne na tlačítko *Log file*, kdy v místě adresáře aplikace se vytvoří *.txt* soubor s názvem *log\_file*, který dané údaje obsahuje, příklad zobrazen na obrázku 24.




**Obrázek 24:** Ukázka *log\_file* souboru. Zdroj vlastní.


Uživatel si může kliknutím na tlačítko *Save evaluation data* uložit *.m* soubor s názvem *Average\_evaluation\_data* v místě adresáře aplikace, v němž budou podsložky pojmenované podle názvu vybraných šumů a v jednotlivých podsložkách uložené hodnoty jednotlivých evaluačních parametrů všech vybraných obrázků, kdy hodnoty budou uloženy v tabulkách. V tabulkách je tolik řádků, kolik hodnotících parametrů, tudíž 5, a sloupců tolik, kolik bylo zvoleno úrovní šumového parametru. Ovšem v případě Gaussovského šumu bude tabulka o tolika sloupcích, kolik bylo zadáno parametrů střední hodnoty, a tolika stránek, kolik bylo zadáno parametrů rozptylu. Nutno podotknout, že každá hodnota každého evaluačního parametru je průměrná hodnota všech vybraných obrázků na dané úrovni šumového parametru daného šumu a pořadí řádků (v případě Gaussovského šumu pořadí buněk) odpovídá pořadí evaluačních parametrů vedle zobrazovacího okna vpravo dole v grafickém uživatelském rozhraní. Tudíž každý řádek (každá buňka u Gaussovského šumu) je pro jeden evaluační parametr v následujícím pořadí: SSIM, SNR, PSNR, MSE a Q-index.

Obrázky 25, 26, 27, 28, 29, 30, 31, 32 a 33 ukazují příklady degradace MR obrazů všemi šumy různými hodnotami šumových parametrů a jejich filtrace pod různými nastaveními  $\sigma^2$ .







**Obrázek 25:** Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami  $M = 0,5$  a  $V = 0,5$ ; šumem Sů&IPepr s hodnotou  $D = 0,5$ ; Poissonovským šumem s hodnotou  $D = 0,5$ ; Spekle šumem s hodnotou  $V = 0,5$  a šum Ricián s hodnotou  $V = 0,5$ . Zdroj originálního obrázku vedoucí diplomové práce, ostatní od něj převzaty a upraveny.




**Obrázek 26:** Výsledek filtrace zašuměných obrázků uvedených v obrázku 25 s hodnotou  $\sigma^2 = 1$ . Zdroj obrázků vedoucí diplomové práce, přičemž byly upraveny.




**Obrázek 27:** Výsledek filtrace zašuměných obrázků uvedených v obrázku 25 s hodnotou  $\sigma^2 = 0,1$ . Zdroj obrázků vedoucí diplomové práce, přičemž byly upraveny.




**Obrázek 28:** Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami  $M = 0,2$  a  $V = 0,2$ ; šumem Sůl&lPepr s hodnotou  $D = 0,2$ ; Poissonovským šumem s hodnotou  $D = 0,2$ ; Spekle šumem s hodnotou  $V = 0,2$  a šum Ricián s hodnotou  $V = 0,2$ . Zdroj originálního obrázku [36], ostatní převzaty z [36] a upraveny.




**Obrázek 29:** Výsledek filtrace zašuměných obrázků uvedených v obrázku 28 s hodnotou  $\sigma^2 = 0,35$ . Obrázky převzaty z [36], přičemž byly upraveny.




**Obrázek 30:** Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami  $M = 0,45$  a  $V = 0,45$ ; šumem Sůl&lPepř s hodnotou  $D = 0,45$ ; Poissonovským šumem s hodnotou  $D = 45$ ; Spekle šumem s hodnotou  $V = 0,45$  a šum Ricián s hodnotou  $V = 0,45$ . Zdroj originálního obrázku [36], ostatní převzaty z [36] a upraveny



**Obrázek 31:** Výsledek filtrace zašuměných obrázků uvedených v obrázku 30 s hodnotou  $\sigma^2 = 0,35$ . Obrázky převzaty z [36], přičemž byly upraveny.



**Obrázek 32:** Vlevo nahoře originální obrázek, následně poškozen Gaussovským šumem s hodnotami  $M = 0$  a  $V = 0,3$ ; šumem Sú&lPepř s hodnotou  $D = 0,25$ ; Poissonovským šumem s hodnotou  $D = 0,35$ ; Spekle šumem s hodnotou  $V = 0,6$  a šum Ricián s hodnotou  $V = 0,1$ . Zdroj originálního obrázku [37], ostatní převzaty z [37] a upraveny.



**Obrázek 33:** Výsledek filtrace zašuměných obrázků uvedených v obrázku 32 s hodnotou  $\sigma^2 = 0,8$ . Obrázky převzaty z [37], přičemž byly upraveny.

## 5 Vyhodnocení vybraných filtrovaných obrazových dat

Níže jsou uvedeny vybrané shrnující tabulky pro všechny hodnotící parametry, které byly vybrány pro tuto diplomovou práci. Pro srovnání byl vybrán Riceovský šum a Sůl&Pepř šum, přičemž Riceovský byl vybrán vzhledem k faktu, že se jedná o nejčastější typ šumu, vyskytující se v MR obrázcích, a Sůl&Pepř šum byl vybrán z důvodu porovnání dvou zásadně odlišných typů šumů. Toto srovnání bylo provedeno pouze na snímcích kolenní chrupavky. Výsledky pro všechny oblasti těla včetně evaluačních grafů, krabicových grafů a shrnujících tabulek jsou uvedeny v přílohách. Samotné srovnání vychází z vybraných shrnujících tabulek, doplněných o základní charakteristiky, a srovnávacích evaluačních grafů.

V tabulkách v prvním řádku je uveden typ šumu a poté filtrační parametr  $\sigma^2$  s použitou hodnotou, přičemž toto je jediný filtrační parametr, který byl v této diplomové práci nastavován, a to na tři různé hodnoty, jelikož jedním z cílů této práce bylo porovnat účinky Non-Local Means filtru pod různými nastaveními tohoto parametru. Ke srovnání byly vybrány hodnoty  $\sigma^2 = 0,1$ ;  $\sigma^2 = 0,5$  a  $\sigma^2 = 0,8$ . Tabulky obsahují hodnoty zkoumaných parametrů v závislosti na hodnotě parametru šumu. Srovnávací evaluační grafy ukazují průběh hodnotících parametrů filtrace, přičemž pro každý parametr je uveden samostatný graf obsahující všechna nastavení  $\sigma^2$  pro oba šумы.

V přílohách již tabulky neobsahují základní charakteristiky dat, místo nich jsou doplněny krabicovými grafy. Evaluační grafy v přílohách jsou uvedeny pro každý šum samostatně bez přímého srovnání. Nutno podotknout, že pro testování bylo vybráno celkem 15 obrázků z každé oblasti, a každá výsledná hodnota je průměrná hodnota všech obrázků dané oblasti těla při daném nastavení filtru a dané hodnotě parametru šumu, přičemž pro testování bylo využito výpočetní a úložné kapacity MetaCentra VO. MetaCentrum VO je virtuální organizace, která umožňuje zdarma využít výpočetní a úložnou kapacitu organizací jako Akademie Věd ČR, Masarykovy univerzity v Brně, a podobně.

### 5.1 Výsledky a srovnání vybraných testování

V tabulkách 2, 3 a 4 jsou uvedeny výsledky testování pro Riceovský šum. První věc, které si lze povšimnout je, že v případě všech parametrů a všech nastavení  $\sigma^2$  je průměr hodnot o něco větší než medián. Z toho lze usuzovat, že rozdíl mezi vyššími výslednými hodnotami hodnotících parametrů a mediánem je o něco větší než rozdíl mezi mediánem a nižšími výslednými hodnotami hodnotících parametrů. S tímto pozorováním koresponduje fakt, že žádná z výsledných hodnot hodnotících parametrů není pod příslušnou dolní hradbou, ovšem lze si povšimnout výskytu odlehklých pozorování nad horní hradbou, a to u nastavení  $\sigma^2 = 0,1$ .

Vzhledem k monotónnímu vývoji hodnot, který lze pozorovat na grafech uvedených na obrázcích 34, 35, 36, 37 a 38, je zřejmé, že k těmto odlehklým pozorováním dochází pro nejnižší hodnotu zašumění s výjimkou parametru MSE, který má rostoucí charakter, a tedy odlehklá pozorování odpovídají vysokým hodnotám šumu. Tato skutečnost odpovídá tomu, že filtr s nízkým nastavením ( $\sigma^2 = 0,1$ ) je efektivní především pro nízké hodnoty zašumění.

Charakteristiky výsledných hodnot pro zbylá dvě nastavení  $\sigma^2$  a samotné výsledné hodnoty jsou podrobněji zhodnoceny u grafického znázornění níže. Nicméně u  $\sigma^2 = 0,8$  lze vidět, že rozsah hradeb a stejně tak

interkvartilové rozpětí je u všech hodnotících parametrů o něco menší než v případě hodnot pro  $\sigma^2 = 0,5$  což může poukazovat na pozvolnější průběh výsledných hodnot pro  $\sigma^2 = 0,8$ .

**Tabulka 2:** Shrnující tabulka výsledků filtrace při nastavení  $\sigma^2 = 0,1$

<b>Riceovský; <math>\sigma^2 = 0,1</math></b>					
<b>Hodnota parametru šumu <math>V</math></b>	<b>SSIM chrupavka</b>	<b>SNR chrupavka</b>	<b>PSNR chrupavka</b>	<b>MSE chrupavka</b>	<b>Q-index chrupavka</b>
<b>0,1</b>	0,3199	0,2809	0,9724	0,0609	0,3401
<b>0,2</b>	0,1951	0,0565	0,7480	0,0645	0,2084
<b>0,3</b>	0,0924	-0,1691	0,5224	0,0696	0,1185
<b>0,4</b>	0,0464	-0,3399	0,3515	0,0755	0,0998
<b>0,5</b>	0,0269	-0,4693	0,2222	0,0955	0,0955
<b>0,6</b>	0,0166	-0,5786	0,1129	0,1075	0,0755
<b>0,7</b>	0,0103	-0,6751	0,0164	0,1185	0,0506
<b>0,8</b>	0,0066	-0,7684	-0,0769	0,2049	0,0295
<b>0,9</b>	0,0048	-0,8412	-0,1498	0,3269	0,0183
<b>Charakteristika</b>					
<b>Průměr</b>	0,0799	-0,3894	0,3021	0,1249	0,1151
<b>Medián</b>	0,0269	-0,4693	0,2222	0,0955	0,0955
<b>Dolní kvartil</b>	0,0103	-0,6751	0,0164	0,0696	0,0506
<b>Horní kvartil</b>	0,0924	-0,1691	0,5224	0,1185	0,1185
<b>Dolní hradba</b>	-0,1129	-1,4341	-0,7426	-0,0038	-0,0513
<b>Horní hradba</b>	0,2156	0,5899	1,2814	0,1919	0,2204

**Tabulka 3:** Shrnující tabulka výsledků filtrace při nastavení  $\sigma^2 = 0,5$

<b>Riceovský; <math>\sigma^2 = 0,5</math></b>					
<b>Hodnota parametru šumu <math>V</math></b>	<b>SSIM chrupavka</b>	<b>SNR chrupavka</b>	<b>PSNR chrupavka</b>	<b>MSE chrupavka</b>	<b>Q-index chrupavka</b>
<b>0,1</b>	0,2982	0,2657	0,9572	0,1431	0,3158
<b>0,2</b>	0,2574	0,1227	0,8142	0,1461	0,2729
<b>0,3</b>	0,2234	-0,0318	0,6597	0,1554	0,2371
<b>0,4</b>	0,1911	-0,1767	0,5148	0,1712	0,2029
<b>0,5</b>	0,1593	-0,311	0,3804	0,1904	0,1693
<b>0,6</b>	0,1288	-0,4319	0,2596	0,2129	0,1371
<b>0,7</b>	0,0997	-0,5398	0,1517	0,2382	0,1065
<b>0,8</b>	0,075	-0,6356	0,0559	0,2671	0,0804
<b>0,9</b>	0,0548	-0,7182	-0,0267	0,305	0,059
<b>Charakteristika</b>					
<b>Průměr</b>	0,1653	-0,2729	0,4185	0,2033	0,1757
<b>Medián</b>	0,1593	-0,311	0,3804	0,1904	0,1693
<b>Dolní kvartil</b>	0,0997	-0,5398	0,1517	0,1554	0,1065
<b>Horní kvartil</b>	0,2234	-0,0318	0,6597	0,2382	0,2371
<b>Dolní hradba</b>	-0,0859	-1,3018	-0,6103	0,0312	-0,0894
<b>Horní hradba</b>	0,4089	0,7302	1,4217	0,3624	0,433

**Tabulka 4:** Shrnující tabulka výsledků filtrace při nastavení  $\sigma^2 = 0,8$

<b>Riceovský; <math>\sigma^2 = 0,8</math></b>					
<b>Hodnota parametru šumu <math>V</math></b>	<b>SSIM chrupavka</b>	<b>SNR chrupavka</b>	<b>PSNR chrupavka</b>	<b>MSE chrupavka</b>	<b>Q-index chrupavka</b>
<b>0,1</b>	0,2915	0,2609	0,9524	0,1724	0,3087
<b>0,2</b>	0,2516	0,1174	0,8089	0,1726	0,2667
<b>0,3</b>	0,2191	-0,0361	0,6554	0,1767	0,2324
<b>0,4</b>	0,1904	-0,1794	0,5121	0,1841	0,202
<b>0,5</b>	0,1647	-0,3077	0,3838	0,196	0,1748
<b>0,6</b>	0,1416	-0,4194	0,272	0,2123	0,1504
<b>0,7</b>	0,1204	-0,5222	0,1693	0,2339	0,128
<b>0,8</b>	0,101	-0,6109	0,0806	0,2613	0,1076
<b>0,9</b>	0,0832	-0,6928	-0,0014	0,2983	0,0888
<b>Charakteristika</b>					
<b>Průměr</b>	0,1737	-0,2657	0,4259	0,2119	0,1843
<b>Medián</b>	0,1647	-0,3077	0,3838	0,196	0,1748
<b>Dolní kvartil</b>	0,1204	-0,5222	0,1693	0,1767	0,128
<b>Horní kvartil</b>	0,2191	-0,0361	0,6554	0,2339	0,2324
<b>Dolní hradba</b>	-0,0276	-1,2513	-0,5598	0,0909	-0,0286
<b>Horní hradba</b>	0,3671	0,693	1,3845	0,3197	0,389



Tabulky 5, 6 a 7 obsahují výsledky pro šum typu Sůl&Pepr. I zde lze pozorovat hodnoty mediánů nižší než hodnoty průměrů stejně jako absenci nízkých odlehlých pozorování a přítomnost vysokých odlehlých pozorování při nastavení  $\sigma^2 = 0,1$  stejně jako u Riceovského šumu. Podobnost také platí v případě interkvartilového rozpětí a rozpětí hradeb.

Na první pohled je zřejmé, že u tohoto typu šumu vychází hodnoty SNR a PSNR výrazně vyšší než u předchozího šumu. Naopak zde je odlehlé pozorování pro SNR, kdežto u Riceovského šumu se odlehlé pozorování u SNR nevyskytuje.

**Tabulka 5:** Shrnující tabulka výsledků filtrace při nastavení  $\sigma^2 = 0,1$

<b>Sůl&amp;Pepr; <math>\sigma^2 = 0,1</math></b>					
<b>Hodnota parametru šumu <math>D</math></b>	<b>SSIM chrupavka</b>	<b>SNR chrupavka</b>	<b>PSNR chrupavka</b>	<b>MSE chrupavka</b>	<b>Q-index chrupavka</b>
<b>0,1</b>	0,131	0,8605	1,552	0,0232	0,3283
<b>0,2</b>	0,1193	0,3853	1,0768	0,0236	0,1271
<b>0,3</b>	0,0583	0,1603	0,8518	0,0239	0,0627
<b>0,4</b>	0,034	0,026	0,7174	0,0255	0,0368
<b>0,5</b>	0,0219	-0,0763	0,6152	0,0305	0,0238
<b>0,6</b>	0,0144	-0,1581	0,5334	0,0403	0,0156
<b>0,7</b>	0,0098	-0,2259	0,4656	0,0626	0,0105
<b>0,8</b>	0,0063	-0,2873	0,4042	0,1217	0,0068
<b>0,9</b>	0,0039	-0,3392	0,3523	0,3139	0,0041
<b>Charakteristika</b>					
<b>Průměr</b>	0,0443	0,0383	0,7298	0,0739	0,0684
<b>Medián</b>	0,0219	-0,0763	0,6152	0,0305	0,0238
<b>Dolní kvartil</b>	0,0098	-0,2259	0,4656	0,0239	0,0105
<b>Horní kvartil</b>	0,0583	0,1603	0,8518	0,0626	0,0627
<b>Dolní hradba</b>	-0,0629	-0,8052	-0,1137	-0,03415	-0,0678
<b>Horní hradba</b>	0,131	0,7396	1,4311	0,12065	0,141

**Tabulka 6:** Shrnující tabulka výsledků filtrace při nastavení  $\sigma^2 = 0,5$


<b>Sůl&amp;Pepř; <math>\sigma^2 = 0,5</math></b>					
<b>Hodnota parametru šumu <math>D</math></b>	<b>SSIM chrupavka</b>	<b>SNR chrupavka</b>	<b>PSNR chrupavka</b>	<b>MSE chrupavka</b>	<b>Q-index chrupavka</b>
<b>0,1</b>	0,4059	1,1422	2,1037	0,0971	0,4260
<b>0,2</b>	0,325	1,0393	1,7307	0,119	0,3418
<b>0,3</b>	0,2786	0,7911	1,4826	0,1447	0,2927
<b>0,4</b>	0,2385	0,5945	1,286	0,1725	0,25
<b>0,5</b>	0,202	0,4331	1,1246	0,2048	0,2109
<b>0,6</b>	0,1685	0,2953	0,9868	0,2403	0,1753
<b>0,7</b>	0,1393	0,1771	0,8686	0,2797	0,1442
<b>0,8</b>	0,112	0,0734	0,7649	0,3255	0,1150
<b>0,9</b>	0,0882	-0,0217	0,6697	0,4061	0,0894
<b>Charakteristika</b>					
<b>Průměr</b>	0,2175	0,5027	1,2241	0,221	0,2272
<b>Medián</b>	0,202	0,4331	1,1246	0,2048	0,2109
<b>Dolní kvartil</b>	0,1393	0,1771	0,8686	0,1447	0,1442
<b>Horní kvartil</b>	0,2786	0,7911	1,4826	0,2797	0,2927
<b>Dolní hradba</b>	-0,0697	-0,7439	-0,0524	-0,0578	-0,0786
<b>Horní hradba</b>	0,4875	1,7121	2,4036	0,4822	0,5155

**Tabulka 7:** Shrnující tabulka výsledků filtrace při nastavení  $\sigma^2 = 0,8$

<b>Sůl&amp;Pepř; <math>\sigma^2 = 0,8</math></b>					
<b>Hodnota parametru šumu <math>D</math></b>	<b>SSIM chrupavka</b>	<b>SNR chrupavka</b>	<b>PSNR chrupavka</b>	<b>MSE chrupavka</b>	<b>Q-index chrupavka</b>
<b>0,1</b>	0,3944	1,3719	2,0633	0,1286	0,4136
<b>0,2</b>	0,3202	1,016	1,7075	0,1488	0,3366
<b>0,3</b>	0,2782	0,7703	1,4618	0,1702	0,2921
<b>0,4</b>	0,2455	0,5855	1,227	0,1941	0,2568
<b>0,5</b>	0,2164	0,44	1,1315	0,2192	0,2255
<b>0,6</b>	0,1901	0,3134	1,0049	0,2474	0,1973
<b>0,7</b>	0,1648	0,198	0,8894	0,2793	0,1703
<b>0,8</b>	0,1417	0,0995	0,791	0,3207	0,1450
<b>0,9</b>	0,1197	0,0094	0,7008	0,3946	0,1214
<b>Charakteristika</b>					
<b>Průměr</b>	0,2301	0,5337	1,2196	0,2336	0,2398
<b>Medián</b>	0,2164	0,44	1,1315	0,2192	0,2255
<b>Dolní kvartil</b>	0,1648	0,198	0,8894	0,1702	0,1703
<b>Horní kvartil</b>	0,2782	0,7703	1,4618	0,2793	0,2921
<b>Dolní hradba</b>	-0,0053	-0,6604	0,0308	0,0065	-0,0124
<b>Horní hradba</b>	0,4483	1,6287	2,3204	0,4429	0,4748


Na níže uvedených grafech jsou grafická srovnání Riceovského a Sůl&Pepř šumů pro jednotlivé hodnotící parametry. Křivky pro Riceovský šum jsou v legendě označeny zkráceně jako *R-šum* a pro Sůl&Pepř šum jako *S&P šum*, v obou případech doplněno o konkrétní nastavení  $\sigma^2$ .

Z obrázku 34 lze vypožorovat očekávané chování parametru SSIM, totiž že s rostoucí hodnotou parametru šumu, hodnota SSIM klesá. Z křivek je patrné, že tento pokles je nejmarkantnější pro výsledky filtračního parametru  $\sigma^2 = 0,1$ . Ačkoliv u Riceovského šumu toto nastavení pro minimální hodnotu parametru šumu (tj. 0,1) vykazuje podobné výsledky jako další dvě zvolená nastavení  $\sigma^2$ , už pro malé zvýšení hodnoty parametru šumu se výsledky prudce zhoršují, zatímco pro  $\sigma^2 = 0,5$  a  $\sigma^2 = 0,8$  vykazují pozvolnější pokles. Srovnáme-li samotné výsledné hodnoty SSIM, lze vidět, že  $\sigma^2 = 0,1$  funguje lépe pro Riceovský šum. Nicméně pro šum Sůl&Pepř dostáváme s vyšší hodnotou  $\sigma^2$  o něco lepší výsledky. Srovnají-li se výsledky pro  $\sigma^2 = 0,5$  a  $\sigma^2 = 0,8$ , vykazují podobné chování, s tím, že lze pozorovat podobný jev jako u  $\sigma^2 = 0,1$ , a to ten, že pro nižší hodnoty parametru šumu lze pozorovat o něco lepší výsledky pro  $\sigma^2 = 0,5$ , kdežto pro vysoké hodnoty parametru šumu se ukazuje, že lepších výsledků dosahuje  $\sigma^2 = 0,8$ . Tím je demonstrován fakt, že pro nižší hodnoty šumového parametru může být silnější nastavení  $\sigma^2$  poněkud kontraproduktivní. Celkově lze z grafu pozorovat, že NLM filtr dává lepší výsledky parametru SSIM pro šum Sůl&Pepř.




**Obrázek 34:** Srovnání průběhu výsledných hodnot hodnotícího parametru SSIM pro šum Riceovský a Sůl&Pepř šum. Zdroj vlastní.

Na obrázcích 35 a 36 lze vidět srovnání pro hodnotící parametry SNR a PSNR. Tyto potvrzují dřívější pozorování, že u šumu Sůl&Pepř jsou výsledky výrazně lepší než u Riceovského šumu. Dokonce už pro nastavení  $\sigma^2 = 0,1$  jsou výsledky filtrace pro tyto dva parametry lepší než pro jakékoliv nastavení u Riceovského šumu. Průběhy hodnot jsou u těchto dvou hodnotících parametrů nejpozvolnější.




**Obrázek 35:** Srovnání průběhu výsledných hodnot hodnotícího parametru SNR pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.



**Obrázek 36:** Srovnání průběhu výsledných hodnot hodnotícího parametru PSNR pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.


Průběh hodnot hodnotícího parametru MSE, který je možno vidět na obrázku 37, koresponduje s tím, že pro vyšší hodnoty zašumění dochází k vyšším chybám. Nárůst chyby je strmější s vyššími hodnotami šumu. Hodnoty MSE jsou pro oba šumy nejmenší při nastavení  $\sigma^2 = 0,1$ ; jelikož čím vyšší je hodnota

Gaussovského rozložení okolí (resp. sousedství) zpracovávaného pixelu a pixelu k porovnání, čím k větší neostrosti může dojít ve výsledném filtrovaném obrázku. Lze pozorovat, že pro vyšší nastavení  $\sigma^2$  dochází u šumu Sůl&Pepř k rychlejšímu nárůstu hodnot, které jsou přibližně od hodnoty zašumění 0,4 vyšší, a tedy horší než u Riceovského šumu.



**Obrázek 37:** Srovnání průběhu výsledných hodnot hodnotícího parametru MSE pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.

V závěru lze na obrázku 38 vidět, že hodnoty Q-indexu vykazují podobné chování jako u parametru SSIM, včetně o něco lepších výsledků u šumu Sůl&Pepř, přičemž v tomto případě lze pozorovat dobrý výsledek nastavení  $\sigma^2 = 0,1$  i u Sůl&Pepř šumu, což v případě hodnotícího parametru SSIM neplatí. Celková podobnost se SSIM je dána obdobným významem obou veličin, to je mírou podobnosti.



**Obrázek 38:** Srovnání průběhu výsledných hodnot hodnotícího parametru SNR pro šum Ricián a Sůl&Pepř šum. Zdroj vlastní.

## 6 OTSU segmentace

Tato kapitola slouží pro úvod do segmentační OTSU metody, která je rozebrána v podkapitole 6.1. V další části je řešena analýza efektivity multilevel OTSU metody mezi originálním, zašuměným a filtrovaným obrázkem při aplikaci NLM filtru.

### 6.1 Segmentační OTSU metoda

Segmentace je metoda zpracování obrazu umožňující rozpoznávání jeho částí, a to oddělováním zájmových objektů v obraze od ostatních. Mezi zájmové objekty mohou patřit orgány s patologickými změnami a podobně. Pro realizaci segmentace jsou využívány algoritmy, které jsou děleny na následující techniky:

- Metody vycházející z detekce hran
- Statické metody
- Znalostní metody
- Metody orientované na regiony v obraze
- Hybridní metody

OTSU metoda patří mezi Statické metody a nyní bude rozebrán její princip. Jedná se o techniku, která vychází z klasického prahování, jejíž princip využívá určení nejlepší prahovací úrovně z histogramu zpracovávaného obrázku, a to výpočtem rozptylu. Je určen tzv. vnitřní rozptyl a mezi-rozptyl. Vnitřní rozptyl vychází z následujícího vztahu: [44]

$$\sigma_w^2 = W_b * \sigma_b^2 + W_f * \sigma_f^2 \quad (32)$$

Kde  $W_b$  představuje váhu pozadí,  $\sigma_b^2$  je rozptyl pozadí,  $\sigma_f^2$  je rozptyl popředí a  $W_f$  je váha popředí. Vnitřní rozptyl  $\sigma_w^2$  je pro každý práh počítán, a práh, který má nejmenší hodnotu  $\sigma_w^2$  je nejlepší úrovní prahování pro zpracovávaný obrázek. Nevýhodou tohoto přístupu je jeho vysoká náročnost, co se týče výpočetního výkonu, jelikož je nutno počítat váhu a průměrnou hodnotu intenzity, z které je získáván rozptyl pro pozadí a popředí obrázku. Z toho důvodu je dávaná přednost přístupu užitím mezi-rozptylu, který je výpočetně méně náročnější a vychází z následujícího vzorce: [44]


$$\sigma_B^2 = W_b * W_f * (\mu_b - \mu_f)^2 \quad (33)$$

Kde  $W_b$  a  $W_f$  znamenají totéž, jako u vzorce 32,  $\mu_b$  a  $\mu_f$  představují průměrnou hodnotu intenzity pozadí a popředí. Mezi-rozptyl  $\sigma_B^2$  je opět spočítán pro každý práh, ovšem nejlepší úrovní pro prahování pro zpracovávaný obrázek je nejvyšší hodnota mezi-rozptylu. Přístup pomocí mezi-rozptylu je rychlejší, jelikož je počítána jenom váha a průměrná hodnota intenzity pozadí a popředí. [44]

### 6.1.1 Princip OTSU metody využívající mezi-rozptyl

Jak je již zmiňováno v podkapitole 6.1, OTSU metoda využívá pro určení nejlepší prahu pro zpracovávání snímek hodnotu mezi-rozptylu nebo vnitřního rozptylu. Pro tuto práci je používána OTSU metoda využívající mezi-rozptyl pro určení nejlepšího prahu z důvodu popsaného v podkapitole 6.1.

Nyní bude uveden názorný příklad. Je dán testovací obrázek s velikostí 6×6 pixelů a s šesti rozdílnými odstíny šedi, uvedeno na obrázku 39, kde je také uveden jeho histogram. Na ose x histogramu se nachází rozložení jednotlivých odstínů šedi, na ose y je hojnost výskytu pixelů s daným odstínem šedi.



**Obrázek 39:** Testovaný obrázek s jeho histogramem [44]

Jak lze vidět, odstínů šedi je 6, tudíž mezi-rozptyl je počítán šestkrát (vždy pro každý jednotlivý odstín šedi je hodnota mezi-rozptylu počítaná zvlášť). Mezi-rozptyl je počítán dle vzorce 33 uvedeného v podkapitole 6.1. Jednotlivé proměnné tohoto vzorce jsou počítány následovně: [44]

$$W_b = \sum_{i=1}^k \frac{n_i}{N} \quad (34)$$

$$W_f = \sum_{i=k+1}^L \frac{n_i}{N} \quad (35)$$


$$\mu_b = \sum_{i=1}^k \frac{n_i * i}{N_k} \quad (36)$$

$$\mu_f = \sum_{i=k+1}^L \frac{n_i * i}{N - N_k} \quad (37)$$

Kde  $L$  představuje pixely daného obrázku s rozdílnými odstíny šedi v rozmezí  $[0, 1, \dots, L]$ ,  $i$  znamená odstín šedi,  $n_i$  je počet pixelů s daným odstínem šedi. Souhrnné množství počtu pixelů je dáno jako  $N = n_0 + n_1 + \dots + n_L$ . Pixely jsou rozčleněny na dvě skupiny, a to skupinu  $b$  a  $f$  (skupina  $b$  je pro pozadí snímku a skupina  $f$  pro popředí snímku) podle úrovně prahování  $k$ .


Nejdříve je spočítána průměrná hodnota intenzity pro pozadí a váha, kdy jejich výpočet pro práh č. 3 je uveden na obrázku 40 včetně histogramu pro pozadí obrázku.





**Obrázek 40:** Výpočet váhy a průměrné intenzity pro pozadí testovaného obrázku. Převzato a upraveno z [44]

Poté, co jsou spočítány potřebné hodnoty pro pozadí obrázku, je proveden analogický výpočet pro popředí; příklad je uveden na obrázku 41.



**Obrázek 41:** Příklad analogického výpočtu průměrné hodnoty intenzity a váhy pro popředí obrázku. Převzato a upraveno z [44]


Nyní jsou vypočítány veškeré potřebné hodnoty, které jsou uvedeny v rovnici 33, tudíž je možno spočítat samotnou hodnotu mezi-rozptylu:

$$\sigma_B^2 = W_b * W_f * (\mu_b - \mu_f)^2$$

$$\sigma_B^2 = 0,4722 * 0,5278 * (0,6471 - 3,8947)^2$$

$$\sigma_B^2 = 2,6285$$

Výsledná hodnota mezi-rozptylu pro odstín šedi číslo 3 je 2,6285. Kdyby byly spočítány hodnoty mezi-rozptylu pro zbytek odstínů šedi, vyšlo by, že právě spočítaná hodnota mezi-rozptylu je nejvyšší hodnotou. To znamená, že tato hodnota je nejlepší úroveň prahování pro segmentaci tohoto obrázku. Na obrázku 42 je uvedeno srovnání testovaného obrázku a obrázku po jeho segmentaci dle výsledné nejlepší úrovně prahování.

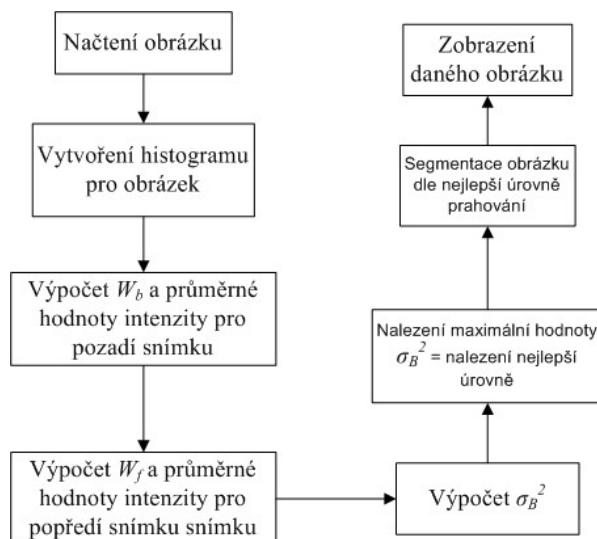


**Obrázek 42:** Srovnání testovaného obrázku a obrázku po jeho segmentaci [44]


### 6.1.1.1 Implementace algoritmu využívající OTSU metodu

Implementace algoritmu je složena z 8 až 9 kroků, záleží na tom, zdali se jedná o klasickou OTSU metodu nebo multilevel OTSU metodu. Prvně bude popsána implementace klasické OTSU metody.

Klasická OTSU metoda je složena z 8 kroků. V prvním kroku je zahrnuto načtení obrázku z jeho adresáře na počítači a ve druhém je vytvořen histogram zpracovávaného obrázku. V dalších krocích jsou vypočítány váhy a průměrné hodnoty intenzit pro každý odstín šedi jak pro pozadí, tak pro popředí obrázku. Poté je vypočítán mezi-rozptyl pro jednotlivé odstíny šedi. Dále je objevena maximální hodnota mezi-rozptylu, kdy odstín šedi mající tuto hodnotu je nejlepší prahovací úroveň, dle které je obrázek segmentován. Segmentace v tomto případě znamená, že dojde ke změně hodnoty odstínů šedi každého pixelu obrázku, a to na pixely popředí nebo pozadí, tudíž výsledkem je binární obrázek, který je v posledním kroku zobrazen. Na obrázku 43 je vývojový diagram algoritmu pro OTSU metodu a příklad binárního obrázku je na obrázku 44.



**Obrázek 43:** Vývojový diagram algoritmu pro multilevel OTSU metodu. Převzato a upraveno z [44]



**Obrázek 44:** Vlevo originální obrázek a napravo tentýž obrázek po segmentaci klasickou OTSU metodou [44]

Klasickou OTSU metodou je segmentace obrázku prováděna podle jedné prahovací úrovně, ale multilevel OTSU metodou je obrázek segmentován dle více než jedné prahovací úrovně. Hlavní difference je, že při

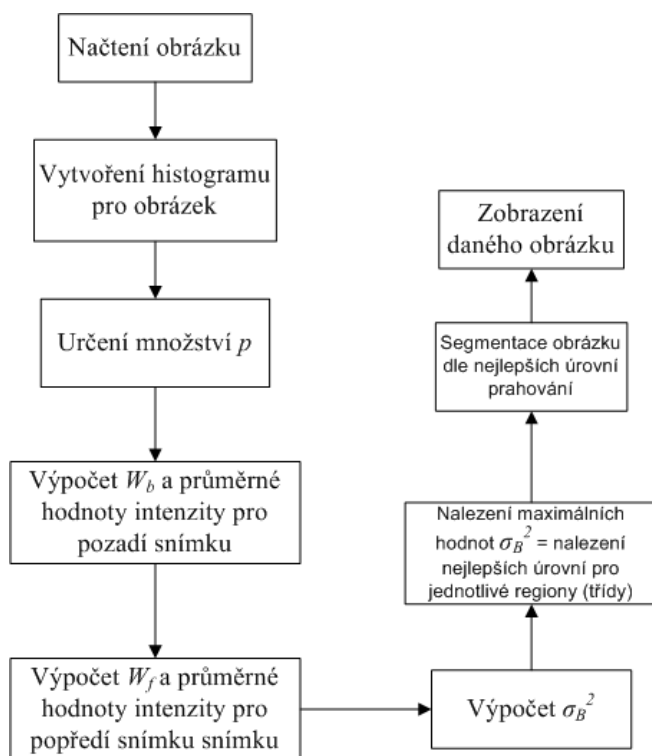
hledání jedné úrovně prahování je daná úroveň hledaná z celého histogramu. Ale u multilevel OTSU metody je histogram obrázku rozdělen na několik stejně velkých oblastí, přičemž pro každou oblast je zjištěna individuální prahovací úroveň a obrázek je segmentován dle všech zjištěných úrovní. Žádané množství úrovní je označeno jako  $p$  a  $L$  nám představuje pixely s odlišnými odstíny šedi v rozmezí  $[0, 1, \dots, L]$ . Šířka, respektive velikost regionu (třídy) je označena jako  $a$  a definovaná následovně: [44]

$$a = \frac{L}{p} \quad (38)$$

Množství regionů (tříd), na které bude histogram rozdělen, je roven počtu žádanému množství úrovní prahování, kdy jednotlivé úrovně prahování jsou označeny jako  $P$ . Mezi-rozptyl je definován stejně jako ve vzorci 33. Nejlepší úrovně prahování pro každý region (třidu) jsou dány dle vzorce 39: [44]

$$P_p = \max_p (\sigma_B^2) \quad (39)$$


Bylo by nutno nalézt pro jakýkoliv obrázek např. 4 úrovně prahování, počet regionů (tříd) by byl totožný. Nejlepší úroveň prahování pro první region (třidu) by byla označena jako  $P_1$ , která by byla získána užitím maximálního mezi-rozptylu pro tento region (třidu), tudíž  $P_1 = \max_1 (\sigma_B^2)$ . Zpracovávaný obrázek by měl 5 odstínů šedi. Na obrázku 45 je uveden vývojový diagram algoritmu pro multilevel OTSU metodu.




**Obrázek 45:** Vývojový diagram algoritmu pro multilevel OTSU metodu. Převzato a upraveno [44]

## 6.2 Vyhodnocení multilevel OTSU segmentace

Níže jsou uvedeny tabulky pro tři hodnotící parametry MSE, SSIM a SNR, které byly vybrány pro vyhodnocení multilevel OTSU segmentace mezi nativním a zašuměným obrázkem a mezi nativním a filtrovaným obrázkem. Jako šumy byly vybrány Riceovský a Sůl&Pepř z oblasti mozku a prostaty. Na obrázcích 46 a 47 jsou příklady segmentace.



**Obrázek 46:** Vlevo v horní řadě nativní obrázek, následné dva obrázky po filtraci, kdy byly poškozeny šumem Ricián s hodnotami  $V = 0,1$  a  $V = 0,3$ . Pod nimi jejich segmentace pro úroveň segmentační třídy 3. Zdroj nativního obrázku [36], ostatní převzaty z [36] a upraveny.



**Obrázek 47:** Vlevo v horní řadě nativní obrázek, následné dva obrázky po zašumění Sůl&Pepř šumem s hodnotami  $D = 0,1$  a  $D = 0,5$ . Pod nimi jejich segmentace pro úroveň seg. třídy 8. Zdroj nativního obrázku [37], ostatní převzaty z [37] a upraveny.

Tabulky 8 až 11 jsou rozděleny na “kvadranty“, přičemž v levé části tabulek jsou uvedeny hodnoty při srovnání nativního a zašuměného obrázku, vpravo při srovnání nativního a filtrovaného obrázku. V horních polovinách tabulek se výsledky vztahují k segmentaci pro 3 segmentační třídy, zatímco v dolních polovinách pro 8 segmentačních tříd. Samotné výsledky měřených parametrů jsou podobně jako v podkapitole 5.1 vztaženy k vybraným hodnotám zašumění. Použitá síla filtru je  $\sigma^2 = 1$ .

V tabulce 8 v levé části lze vidět očekávaný vývoj hodnot, totiž že s rostoucí hodnotou  $V$  klesá SSIM a zvyšuje se odstup signálu od šumu, s tím, že SNR nabývá čím dál nižších hodnot a to záporných. Hodnota MSE stoupá. V pravé části tabulky lze pozorovat, že po filtraci došlo k výraznému nárůstu SSIM. Pro nižší hodnoty  $V$  zároveň došlo k přiblížení SNR k nule oproti situaci před filtrací. Srovnají-li se výsledky pro počet segmentačních tříd 3 a 8, lze si povšimnout obecně horších výsledků pro 8 segmentačních tříd. Tento fakt může být způsoben povahou obrázku, konkrétně nízkou variabilitou hodnot jasu pixelů. Nejvýrazněji lze toto pozorovat u parametru MSE.

**Tabulka 8:** Tabulka výsledků segmentace pro Riceovský šum (mozek)

<b>Riceovský; <math>\sigma^2 = 1</math>; mozek</b>						
<b>Hodnota parametru šumu <math>V</math></b>	<b>Segmentační třídy: 3 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 3 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,2168	-0,4821	0,0925	0,8186	-0,2586	0,0555
<b>0,3</b>	0,0555	-2,679	0,7004	0,7975	-0,413	0,0695
<b>0,5</b>	0,0344	-4,0281	1,3961	0,5915	-1,3967	0,1939
<b>0,7</b>	0,0264	-4,8766	1,9506	0,1488	-4,5536	1,5142
<b>0,9</b>	0,0238	-5,3152	2,2892	0,5169	-6,1762	3,0635
<b>Hodnota parametru šumu <math>V</math></b>	<b>Segmentační třídy: 8 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 8 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,1318	-3,1447	2,1685	0,7474	-1,251	0,4233
<b>0,3</b>	0,061	-5,8723	10,2471	0,13	-2,8732	1,6321
<b>0,5</b>	0,0368	-7,6636	20,0881	0,0646	-5,5951	7,5463
<b>0,7</b>	0,0247	-8,5239	26,6338	0,0259	-8,7941	27,9327
<b>0,9</b>	0,0189	-8,8204	29,2944	0,1723	-9,7707	38,9089

Tabulka 9 udává výsledné hodnoty pro oblast prostaty. Oproti mozku lze vidět o něco menší vliv šumu, zároveň segmentace pro nativní a filtrovaný obrázek vykazuje snížení parametru SSIM s výjimkou hodnoty  $V = 0,9$  pro hodnotu segmentační třídy 3. To může dáno tím, že obrázek oblasti prostaty má jinou strukturu oproti oblasti mozku, dále nastavením  $\sigma^2$ , které může mít pro nižší hodnoty  $V$  spíše kontraproduktivní efekt, jak je tomu v podkapitole 5.1. Stejně jako v případě oblasti mozku, lze pozorovat horší výsledky pro hodnotu segmentační třídy 8.

**Tabulka 9:** Tabulka výsledků segmentace pro Riceovský šum (prostata)

<b>Riceovský; <math>\sigma^2 = 1</math>; prostata</b>						
<b>Hodnota parametru šumu <math>V</math></b>	<b>Segmentační třídy: 3 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 3 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,5277	-0,8244	0,1887	0,4152	-0,7866	0,2417
<b>0,3</b>	0,2976	-1,5163	0,5094	0,3883	-1,0125	0,2949
<b>0,5</b>	0,2024	-2,3448	1,031	0,2928	-1,7478	0,5551
<b>0,7</b>	0,1668	-2,9017	1,4412	0,1151	-3,0261	1,4364
<b>0,9</b>	0,1468	-3,1865	1,6769	0,1956	-3,7893	2,2213
<b>Hodnota parametru šumu <math>V</math></b>	<b>Segmentační třídy: 8 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 8 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,3695	-3,6208	4,5446	0,2935	-3,3284	4,1531
<b>0,3</b>	0,1998	-4,713	10,0207	0,2014	-3,9011	5,9452
<b>0,5</b>	0,1238	-5,667	16,7831	0,1026	-5,0383	11,455
<b>0,7</b>	0,0914	-6,1562	20,991	0,0215	-6,4419	22,9801
<b>0,9</b>	0,0677	-6,2113	21,822	0,0206	-7,0388	29,826

Tabulka 10 uvádí výsledky pro šum Sůl&Pepř v rámci oblasti mozku. V levé části tabulky si lze povšimnout výrazně většího vlivu šumu na parametr SSIM oproti Riceovskému šumu. Naproti tomu parametr SNR vykazuje příznivější hodnoty, neboť v tomto případě nejsou všechny záporné a obecně jsou blíže nule. Filtrace v tomto případě přispěla k lepším výsledkům pro parametry SSIM a MSE pro obě hodnoty segmentační třídy. Stejně jako u Riceovského šumu lze pozorovat výrazné zvýšení MSE pro hodnotu segmentační třídy 8.

**Tabulka 10:** Tabulka výsledků segmentace pro Sůl&Pepř šum (mozek)

<b>Sůl&amp;Pepř; <math>\sigma^2 = 1</math>; mozek</b>						
<b>Hodnota parametru šumu <math>D</math></b>	<b>Segmentační třídy: 3 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 3 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,0674	-0,0562	0,2449	0,8136	-0,0962	0,0527
<b>0,3</b>	0,0286	-1,1248	0,5827	0,5344	-0,3919	0,1046
<b>0,5</b>	0,0149	-2,0086	0,9219	0,1211	-1,8763	0,3845
<b>0,7</b>	0,0081	-2,7431	1,2596	0,0512	-2,6127	0,6893
<b>0,9</b>	0,0033	-3,3552	1,5993	0,0195	-3,0608	1,0717
<b>Hodnota parametru šumu <math>D</math></b>	<b>Segmentační třídy: 8 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 8 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,0797	-2,4813	3,0596	0,3144	0,4875	0,4092
<b>0,3</b>	0,0256	-2,8017	6,5834	0,0931	-1,907	1,3629
<b>0,5</b>	0,0147	-4,1728	10,3948	0,0541	-3,5453	4,0161
<b>0,7</b>	0,0059	-4,9169	12,7104	0,033	-5,4051	9,12
<b>0,9</b>	0,0024	-6,1909	18,0811	0,0114	-5,9095	12,5047

Z tabulky 11 lze vyvodit vesměs stejné závěry, které se týkají tabulky 10, tentokrát pro oblast prostaty. S ohledem na rozdílnou strukturu obrázku lze vidět o něco lepší výsledky SSIM a MSE, naopak o něco horší výsledky SNR.




**Tabulka 11:** Tabulka výsledků segmentace pro Sůl&Pepř šum (prostata)

<b>Sůl&amp;Pepř; <math>\sigma^2 = 1</math>; prostata</b>						
<b>Hodnota parametru šumu <math>D</math></b>	<b>Segmentační třídy: 3 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 3 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,2465	0,6264	0,3239	0,4166	0,2139	0,1853
<b>0,3</b>	0,1136	0,4075	0,6826	0,3912	0,0291	0,2034
<b>0,5</b>	0,0675	-0,0997	0,98	0,2988	-0,0233	0,2636
<b>0,7</b>	0,0393	-0,5913	1,2678	0,1603	-0,4742	0,4006
<b>0,9</b>	0,012	-1,0475	1,5881	0,034	-0,7523	0,8816
<b>Hodnota parametru šumu <math>D</math></b>	<b>Segmentační třídy: 8 Pro nativ. a zašuměný</b>			<b>Segmentační třídy: 8 Pro nativ. a filtrovaný</b>		
	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>	<b>SSIM</b>	<b>SNR</b>	<b>MSE</b>
<b>0,1</b>	0,2968	-0,724	2,0868	0,2954	-0,9902	0,9171
<b>0,3</b>	0,1212	-1,6672	5,7855	0,2037	-1,5927	1,533
<b>0,5</b>	0,0618	-2,481	9,4277	0,159	-1,9791	2,3495
<b>0,7</b>	0,0311	-3,1891	13,0356	0,114	-2,5592	4,0419
<b>0,9</b>	0,0069	-3,5857	15,9913	0,0299	-3,3575	8,5829


Na obrázcích 48 až 53 lze vidět shrnující evaluační grafy pro výsledky segmentace, kdy hodnoty vycházejí z výše uvedených tabulek. Na ose x je rozsah parametru šumu a na ose y rozsah hodnotícího parametru. Grafy jsou opatřeny legendou, která barevně rozlišuje jednotlivé křivky podle toho, kterému typu šumu odpovídají, zda se týkají hodnot pro srovnání mezi nativním a zašuměným obrázkem nebo mezi nativním a filtrovaným obrázkem, a jaké úrovně segmentační třídy se týkají.

Na obrázku 48 jsou křivky pro parametr SSIM oblasti mozku. U Riceovského šumu po filtraci lze pozorovat určitou nestabilitu chování pro úroveň segmentační třídy 3, nicméně také nejlepší výsledky. Také lze vidět, že hodnoty u Ricoevského šumu po filtraci pro obě úrovně segmentační třídy spolu s hodnotami Sůl&Pepř šumu po filtraci pro úroveň segmentační třídy 3, se vymykají ostatním hodnotám. Ostatní křivky poukazují na menší hodnoty, avšak stabilnější průběh.




**Obrázek 48:** Hodnoty SSIM pro oblast mozku. Zdroj vlastní.

Na obrázku 49 je stejné srovnání, ovšem tentokrát pro oblast prostaty. Lze pozorovat o něco vyrovnanější rozestup hodnot mezi jednotlivými křivkami. U Riceovského šumu po filtraci lze opět pozorovat určitou nestabilitu chování pro úroveň segmentační třídy 3. Nejvyšších hodnot dosahují data Riceovského šumu před a po filtraci, také data Sůl&Pepř šumu po filtraci, konkrétně pro úroveň segmentační třídy 3. Zároveň lze vidět fakt dokumentovaný v tabulkách, a to ten, že pro oblast prostaty jsou hodnoty SSIM menší než pro oblast mozku.




**Obrázek 49:** hodnoty SSIM pro oblast prostaty. Zdroj vlastní.

Obrázek 50 zobrazuje křivky pro hodnotu SNR oblasti mozku. Hodnoty Riceovského šumu pro úroveň segmentační třídy 8 po filtraci a před filtrací, také segmentační třídy 3 po filtraci, vykazují největší pokles. Ostatní mají pozvolnější průběh a po většinu doby nejlepších výsledků dosahuje křivka znázorňující hodnoty šumu Sůl&Pepř pro úroveň segmentačních tříd 3, a to pro data po filtraci.




**Obrázek 50:** Hodnoty SNR pro oblast mozku. Zdroj vlastní.

Obrázek 51 zobrazuje tutéž hodnotu jako předchozí obrázek, ale pro oblast prostaty. Hodnoty Riceovského šumu před filtrací pro úroveň segmentační třídy 8 a také v případě po filtraci vykazují nejhorší výsledky, což je víceméně stejný stav, jako v případě oblasti mozku. Nejlepší výsledky vykazují hodnoty šumu S&P šum pro úroveň segmentační třídy 3, jak mezi nativním a zašuměným obrázkem, tak mezi nativním a filtrovaným obrázkem, a opět, jak v případě pro oblast mozku, hodnoty mezi originálním a filtrovaným obrázkem mají po většinu doby nejlepší výsledky.




**Obrázek 51:** Hodnoty SNR pro oblast prostaty. Zdroj vlastní.

Na obrázku 52 jsou křivky dokumentující průběh MSE pro oblast mozku. Je zcela zřejmé, že hodnoty před a po filtraci u obou šumů pro úroveň segmentační třídy 8 vykazují nejprudší průběh. Ostatní hodnoty mají značně stabilnější průběh a také dosahují výrazně menších hodnot.



**Obrázek 52:** Hodnoty MSE pro oblast mozku. Zdroj vlastní.

Obrázek 53 dokumentuje totéž jako obrázek 52, ovšem pro oblast prostaty. Stejně jako pro oblast mozku, zde hodnoty před a po filtraci pro úroveň segmentační třídy 8 u obou šumů také vykazují nejprudší průběh, ale dosahují menších hodnot. Ostatní hodnoty jsou podobné hodnotám pro oblast mozku.



**Obrázek 53:** Hodnoty MSE pro oblast prostaty. Zdroj vlastní.

## 7 Závěr

Tato práce je zaměřena na filtraci zašuměného MR obrazu užitím Non-Local Means metody, přičemž nejčastější typ šumu, kterým jsou MR obrázky poškozeny je Riceovský, na který je nejúčinnější právě tato metoda.

Byla vytvořena edukativní aplikace v prostředí MATLAB, kde lze nahrát obrázky z MR ve formátu *.jpg* nebo *.png*. Následně lze obrázky poškodit vybranými šumy pod zadanými hodnotami šumových parametrů, které lze následně filtrovat Non-Local Means filtrem, kdy po filtraci jsou taktéž zobrazeny hodnotící parametry filtrace. Díky této aplikaci lze porovnávat účinky různých nastavení filtrace na různé obrázky poškozenými různými šumy.

V práci je uvedeno také zhodnocení filtrace. Ve zhodnocení byl zjištěn důležitý fakt, a to, že větší síla filtru neznamena vždy lepší výsledek filtrace, jelikož při větší síle dochází k většímu rozmazání obrázku a při malých úrovních šumů je tím způsobeno jeho příliš velké rozmazání, což může mít kontraproduktivní účinek. Účinnost různých úrovní síly filtru na obrázky se odvíjí od charakteru obrázku, typu šumu a hodnoty šumového parametru. Obecně ale platí, že síla filtru by se měla zvyšovat s rostoucí úrovní šumu, ovšem může se stát, že při příliš vysoké úrovni šumu bude tato filtrační metoda v podstatě neúčinná.

V další části je zhodnocení multilevel OTSU segmentace pro dvě úrovně segmentační třídy, která byla testována mezi nativním a zašuměným obrázkem a mezi nativním a filtrovaným obrázkem. Výsledky závisí podobně jako v předchozí části na kombinaci charakteru obrázků, typu šumů, úrovni šumového parametru, a v tomto případě také na úrovni segmentační třídy. V případě porovnávání segmentace mezi nativním a filtrovaným obrázkem také závisí na síle Non-Local Means filtru.

Přesto, že je Non-Local Means filtrace nejúčinnější na Riceovský typ šumu, její značnou nevýhodou je vysoká výpočetní náročnost, tudíž jedna z možností rozšíření této práce je optimalizace tohoto filtru. Další možností rozšíření je, aby aplikace měla možnost použít více typů filtrů, tím by se daly porovnávat jejich účinky mezi sebou. Zajímavou možností rozšíření této práce bezesporu také je, porovnat účinky různých filtrů na různých šumech na obrázcích získaných různými vyšetřovacími metodami.

## 8 Seznam použité literatury

- [1] Magnetická rezonance. *Nemocnice Třinec* [online]. [cit. 2018-10-02]. Dostupné z: <http://www.nemtr.cz/index.php/cs/vysetrovaci-metody/magneticka-rezonance>
- [2] MAZANEC, Jiří. *Program pro prohlížení a segmentaci 3D MRI dat*. Praha, 2008. Diplomová práce. České vysoké učení technické v Praze, Fakulta elektrotechnická. Vedoucí práce Dr. Ing. Jan Kybic.
- [3] FEBEROVÁ, Bc. Karolína. *Problematika monitorování vitálních funkcí u MR vyšetření*. Ostrava, 2014. Diplomová práce, Fakulta elektrotechniky a informatiky. Vysoká škola báňská – Technická univerzita Ostrava. Vedoucí práce Ing. Vladimír Kašík, Ph.D.
- [4] FIALA, DIS., Jiří. *Zobrazování mozku magnetickou rezonancí, vyšetřovací protokoly*. Olomouc, 2014. Bakalářská práce. Univerzita Palackého v Olomouci, Fakulta zdravotnických věd. Vedoucí práce MUDr. Eva Čecháková.
- [5] NĚMCOVÁ, Bc. Simona. *Zobrazování chrupavek na magnetické rezonanci*. Brno, 2017. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Vedoucí práce Ing. Lucie Krátká.
- [6] BENEŠ, Petr. *SVĚTOVÍ VÝROBCI MAGNETICKÝCH REZONANCÍ*. Plzeň, 2012. Bakalářská práce. Západočeská univerzita v Plzni, Fakulta zdravotnických studií. Vedoucí práce Prof. Ing. Josef Kott DrSc.
- [7] VICIANOVÁ, Veronika. *Extrakce objektů z medicínských obrazů na základě metody aktivních kontur*. Ostrava, 2017. Bakalářská práce. Vysoká škola báňská – Technická univerzita Ostrava. Vedoucí práce Ing. Jan Kubíček.
- [8] SEDLÁŘ, Martin. Magnetická rezonance. In: *Masarykova univerzita, Biofyzikální ústav* [online]. 2011 [cit. 2018-10-04]. Dostupné z: [http://www.med.muni.cz/biofyz/files/nutricnispecialista/MRI\\_2011\\_Sedlar.pdf](http://www.med.muni.cz/biofyz/files/nutricnispecialista/MRI_2011_Sedlar.pdf)
- [9] STĚPÁN, Ing. Miroslav. *Techniky pro získávání základních parametrů NMR signálu* [online]. [cit. 2018-10-04]. ISSN 1213-1539. Dostupné z: <http://www.elektrorevue.cz/clanky/02053/index.html>
- [10] HENDRIX, Alexander. SIEMENS AG MEDICAL SOLUTIONS. *Magnets, Spins, and Resonances: An introduction to the basics of Magnetic Resonance*. © Siemens AG. Erlangen, 2003, 224 s. A91100-M2200-M705-1-7600.

- [11] Šum a jeho odstranění – teorie&praxe. In: *Ústav teorie informace a automatizace* [online]. [cit. 2018-10-05]. Dostupné z: [http://zoi.utia.cas.cz/files/NPGR032/NPGR032\\_03\\_644980.pdf](http://zoi.utia.cas.cz/files/NPGR032/NPGR032_03_644980.pdf)
- [12] BONCELET, Charles. Image Noise Models. *Handbook of Image & Video Processing* [online]. 2nd ed. United States of America: Elsevier Academic Press, 2005, s. 397-409 [cit. 2018-10-05]. ISBN 0-12-119792-1.
- [13] BOYAT, Ajay Kumar a Brijendra Kumar JOSHI. A REVIEW PAPER: NOISE MODELS IN DIGITAL IMAGE PROCESSING. *International Journal of Computer Applications* [online]. 2015, 63-75 [cit. 2018-10-05]. Dostupné z: <https://arxiv.org/ftp/arxiv/papers/1505/1505.03489.pdf>
- [14] PATIDAR, Pawan a Sumit SRIVASTAVA. *International Journal of Computer Applications* [online]. November 2010, 45-50 [cit. 2018-10-05]. Dostupné z: <https://www.ijcaonline.org/volume9/number4/pxc3871846.pdf>
- [15] ABOSHOSHA, Ashraf, M. HASSAN, M. ASHOUR a M. El MASHADE. In: *National Center for Radiation Research and Technology* [online]. Egypt, 2009, s. 245-250 [cit. 2018-10-05]. Dostupné z: <https://ieeexplore.ieee.org/document/5384036>
- [16] TVARŮŽEK, Bc. Marek. *METODY POTLAČENÍ STRUKTURNÍHO ŠUMU TYPU SPEKLE*. Brno, 2013. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Martin Mézl.
- [17] NOBI, M. N. a M. A. YOUSUF. A New Method to Remove Noise in Magnetic Resonance and Ultrasound Images. *JOURNAL OF SCIENTIFIC RESEARCH* [online]. 2011, 81-89 [cit. 2018-10-19]. Dostupné z: <https://www.banglajol.info/index.php/JSR/article/view/5544/5164>
- [18] FERNÁNDEZ, Santiago Aja, Carlos Alberola LÓPEZ a Carl-Fredrik WESTIN. Noise and Signal Estimation in Magnitude MRI and Rician Distributed Images: A LMMSE Approach. *IEEE TRANSACTIONS ON IMAGE PROCESSING* [online]. 2008, 1383-1398 [cit. 2018-10-19]. Dostupné z: <https://ieeexplore.ieee.org/document/4543026?tp=&arnumber=4543026>
- [19] Obrazové filtry. In: *Mendelova univerzita v Brně* [online]. [cit. 2018-10-19]. Dostupné z: [https://is.mendelu.cz/eknihovna/opory/zobraz\\_cast.pl?cast=18431](https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=18431)
- [20] Konvoluční matice. In: *The GIMP DOCUMENTATION* [online]. [cit. 2018-10-19]. Dostupné z: <https://docs.gimp.org/2.2/cs/plugin-convmatrix.html>



- [21] FESSL, Lukáš. *Knihovna pro automatickou detekci a měření objektů v obrazu z mikroskopu*. České Budějovice, 2012. Bakalářská práce. Jihočeská univerzita v Českých Budějovicích, Přírodovědecká fakulta. Vedoucí práce Ing. Miroslav Skrbek, Ph.D.
- [22] Obrazové filtry. In: *Mendelova univerzita v Brně* [online]. [cit. 2018-10-19]. Dostupné z: [https://is.mendelu.cz/eknihovna/opory/zobraz\\_cast.pl?cast=18431](https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=18431)
- [23] PIKORA, Jan. *Implementace grafických filtrů pro zpracování rastrového obrazu*. Brno, 2008. Bakalářská práce. Masarykova univerzita, Fakulta informatiky. Vedoucí práce Mgr. Tomáš Staudek, Ph.D.
- [24] Segmentace obrazu. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001 – [cit. 2018-10-06]. Dostupné z: [https://cs.wikipedia.org/wiki/Segmentace\\_obrazu](https://cs.wikipedia.org/wiki/Segmentace_obrazu)
- [25] Java DIP – Laplacian Operator. In: *Tutorialspoint* [online]. [cit. 2019-02-08]. Dostupné z: [https://www.tutorialspoint.com/java\\_dip/applying\\_laplacian\\_operator.htm](https://www.tutorialspoint.com/java_dip/applying_laplacian_operator.htm)
- [26] JEDLIČKA, Pavel. *Předzpracování medicínských obrazů pro následnou segmentaci*. Plzeň, 2012. Bakalářská práce. Západočeská univerzita v Plzni, Fakulta aplikovaných věd, Katedra kybernetiky. Vedoucí práce Ing. Tomáš Ryba.
- [27] Java DIP – Prewitt Operator. In: *Tutorialspoint* [online]. [cit. 2019-02-08]. Dostupné z: [https://www.tutorialspoint.com/java\\_dip/applying\\_prewitt\\_operator.htm](https://www.tutorialspoint.com/java_dip/applying_prewitt_operator.htm)
- [28] Java DIP – Kirsch Operator. In: *Tutorialspoint* [online]. [cit. 2019-02-08]. Dostupné z: [https://www.tutorialspoint.com/java\\_dip/applying\\_kirsch\\_operator.htm](https://www.tutorialspoint.com/java_dip/applying_kirsch_operator.htm)
- [29] Java DIP – Robinson Operator. In: *Tutorialspoint* [online]. [cit. 2019-02-08]. Dostupné z: [https://www.tutorialspoint.com/java\\_dip/applying\\_robinson\\_operator.htm](https://www.tutorialspoint.com/java_dip/applying_robinson_operator.htm)
- [30] HOLUB, Zbyněk. *REDUKCE ŠUMU U NÍZKODÁVKOVÝCH CT SNÍMKŮ*. Brno, 2015. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Jiří Chmelík.
- [31] ROUSEK, Marek. *Objektivní hodnocení kvality obrazu mluvího znakového jazyka*. Praha, 2016. Bakalářská práce. České vysoké učení technické v Praze, Fakulta elektrotechnická, Katedra radioelektroniky. Vedoucí práce Ing. Martin Bernas, CSc.

- [32] NETUŠIL, Kamil. *Subjektivní a objektivní hodnocení kvality obrazu a videa*. Plzeň, 2011. Bakalářská práce. Západočeská univerzita v Plzni, Fakulta elektrotechnická, Katedra aplikované elektroniky a telekomunikací. Vedoucí práce Ing. Ivo Veřtát.
- [33] ŠIMÍČEK, Bc. Pavel. *PROGRAM PRO HODNOCENÍ KVALITY OBRAZU S VYUŽITÍM NEURONOVÉ SÍTĚ*. Brno, 2008. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav radioelektroniky. Vedoucí práce Ing. Martin Slanina.
- [34] BASHKATOVA, Daria. *Hodnocení kvality obrazu mluvího znakového jazyka*. Praha, 2016. Bakalářská práce. České vysoké učení technické v Praze, Fakulta elektrotechnická, Katedra radioelektroniky. Vedoucí práce Ing. Martin Bernas, CSc.
- [35] TCGA-CESC. In: *The Cancer Imaging Archive* [online]. [cit. 2019-04-10]. Dostupné z: [https://wiki.cancerimagingarchive.net/display/Public/TCGA-CESC?fbclid=IwAR1R8qU7b7IllrTEuhEL42GxziKuEhICDJ8fr\\_R2nF2BS6AkNDqUVxQ-AR4#5afe8019ab1c4d77afad9d1154fc354f](https://wiki.cancerimagingarchive.net/display/Public/TCGA-CESC?fbclid=IwAR1R8qU7b7IllrTEuhEL42GxziKuEhICDJ8fr_R2nF2BS6AkNDqUVxQ-AR4#5afe8019ab1c4d77afad9d1154fc354f)
- [36] LGG-1p19qDeletion. In: *The Cancer Imaging Archive* [online]. [cit. 2019-04-10]. Dostupné z: <https://wiki.cancerimagingarchive.net/display/Public/LGG-1p19qDeletion>
- [37] PROSTATE-DIAGNOSIS. In: *The Cancer Imaging Archive* [online]. [cit. 2019-04-10]. Dostupné z: <https://wiki.cancerimagingarchive.net/display/Public/PROSTATE-DIAGNOSIS>
- [38] RIDER Breast MRI. In: *The Cancer Imaging Archive* [online]. [cit. 2019-04-10]. Dostupné z: <https://wiki.cancerimagingarchive.net/display/Public/RIDER+Breast+MRI>
- [39] MANJÓN, José V., José Carbonell CABALLERO, Juan J. LULL, Gracián García MARTÍ, Luís Martí BONMATÍ a Montserrat ROBLES. MRI denoising using Non-Local Means. *Medical Image Analysis* [online]. 2018, 514-523 [cit. 2019-04-11]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1361841508000248>
- [40] MANJÓN, PHD, José V., Pierrick COUPÉ, PHD, Luis Martí BONMATÍ, PHD, D. Louis COLLINS, PHD a Montserrat ROBLES, PHD. Adaptive Non-Local Means Denoising of MR Images With Spatially Varying Noise Levels. *JOURNAL OF MAGNETIC RESONANCE IMAGING* [online]. 192-203 [cit. 2019-04-11]. ISSN 1522-2586. Dostupné z: <https://onlinelibrary.wiley.com/doi/epdf/10.1002/jmri.22003>

- [41] HOLUB, Bc. Zbyněk. *ODSTRANĚNÍ ŠUMU Z OBRAZŮ KALIBRAČNÍCH VZORKŮ ZÍSKANÝCH ELEKTRONOVÝM MIKROSKOPEM*. Brno, 2017. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Jan Odstrčilík, Ph.D.
- [42] MAHMOUDI, Mona a Guillermo SAPIRO. [online]. In: December 2005, s. 839-842 [cit. 2019-04-11]. DOI: 10.1109/LSP.2005.859509. Dostupné z: <https://ieeexplore.ieee.org/document/1542113/citations?tabFilter=papers#citations>
- [43] Non-local means. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001-[cit. 2019-04-11]. Dostupné z: [https://en.wikipedia.org/wiki/Non-local\\_means](https://en.wikipedia.org/wiki/Non-local_means)
- [44] VALOŠEK, Jan. *Automatizovaný software pro úpravu a analýzu medicínských snímků*. Ostrava, 2015. Bakalářská práce. VŠB - Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky. Vedoucí práce Ing. Jan Kubíček.

## Seznam příloh

### *Příloha I CD (IS Edison)*

Přiložené CD obsahuje:

- Diplomovou práci ve formátu *PDF/A* s označením *LIP0056.pdf*
- Složka *Data*, kde jsou tři podsložky s uloženými obrazovými daty použitými pro hodnocení filtrace v této práci; tabulky, krabicové grafy a evaluační grafy výsledků testování filtrace a obrazová data použitá pro hodnocení segmentace. Součástí je *Data\_Hlavička.pdf* soubor s detailním vysvětlením jednotlivých podsložek.
- Složka *Kódy\_a\_algoritmy* obsahující jednotlivé funkce v *.m* souborech použité pro tuto diplomovou práci, ať už vytvořené či stažené. Součástí je *Algoritmy\_hlavička.pdf* soubor, kde jsou jednotlivé funkce popsány. Dále je obsažena podsložka *NLM\_filter*, obsahující funkce ve formátu *.fig*, *.m* a další *Algoritmy\_hlavička.pdf* soubor, kde je popsán účel funkcí. Taktéž je obsažena podsložka *OTSU* obsahující *.m* soubory, které byly použity pro multilevel OTSU segmentaci. Součástí je *.txt* soubor obsahující odkazy ke stažení funkcí, které byly pro tuto práci staženy.